## **WORLD WIDE WEB NEWS RETRIEVAL SYSTEM**

Patent number:

JP10254912

Publication date:

1998-09-25

Inventor:

NEHAB SMADAR; WICKRAMARATNE MANJULA G;

KLARK PAUL L

Applicant: Classification: **CANON INFORMATION SYST INC** 

G06F17/30; G06F12/00; G06F13/00

international:european:

G06F17/30W1F

Application number: JP19970307770 19971006 Priority number(s): US19960726853 19961004

Also published as:

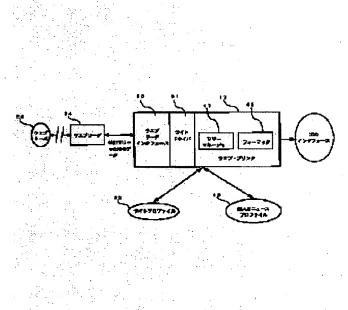
EP0834822 (A2) US6029182 (A1)

EP0834822 (A3)

Report a data error here

## Abstract of **JP10254912**

PROBLEM TO BE SOLVED: To naturally read the data by flattening the data tree where the data extracted from a hypermedia document are built into a linear document and then turning this document into a format. SOLUTION: A web printer 17 accesses various web sites and gives a command to a web reader 34 to secure the connection to a web via a web server 35 and based on the information stored in a personal news profile 19 and a site profile 20, so that the data are retrieved from those web sites. The reader 34 sends the retrieved data to the printer 17, and the printer 17 uses the received data to assemble an extracted data tree. Then the printer 17 flattens the assembled data tree to converts it into a linear document and then turns this document into an output format via an output interface.



Data supplied from the esp@cenet database - Worldwide

## (19)日本国特許庁(JP)

# (12) 公開特許公報(A)

(11)特許出願公開番号

# 特開平10-254912

(43)公開日 平成10年(1998) 9月25日

(51) Int.Cl. <sup>6</sup>	識別記号	F I
G06F 17/30		G 0 6 F 15/403 3 8 0 Z
12/00	5 4 7	12/00 5 4 7 H
13/00	3 5 1	13/00 3 5 1 G
15,55		15/40 3 1 0 F
		15/419 3 2 0
		審査請求 未請求 請求項の数54 OL 外国語出願 (全 116 頁)
(21)出願番号	特願平9-307770	(71) 出願人 592208172
		キヤノン インフォメーション システム
(22)出願日	平成9年(1997)10月6日	ズ インク・
	,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,	Canon Information S
(31) 层先梅士惠采县	08/726853	vstems. Inc.
(32)優先日	1996年10月4日	アメリカ合衆国 カリフォルニア州
(33)優先権主張国	米国(US)	92612, アーバイン, イノベーション ド
		ライブ 110
		(72)発明者 スメーダー ネハブ
		アメリカ合衆国 カリフォルニア州
		94306, パロ アルト, ウイルキー
		ウエイ 4020
		(74)代理人 弁理士 大塚 康徳 (外1名)
		最終頁に続く
	,	AUTO STILLING V

# (54) 【発明の名称】 ワールドワイド・ウエブ・ニュース検索システム

## (57)【要約】 (修正有)

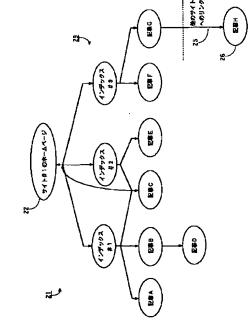
【課題】目的とするニュースを適確容易にアクセスする。

【解決手段】 (1) ウエブ・リーダを起動しワールド・

ワイド・ウエブに接続し、(2) ウエブサイトアドレス情報及びウエブサイトコマンドを検索して取り出し、(3) ウエブサイトにアクセスするように、ウエブ・リーダに命令し、(4) ループを形成するハイパー・メディア・リンクを避け、リンクされたリストを参照して前記ウエブサイトコマンドに基づいてウエブサイトからウエブサイトデータをダウンロードし、(5) ウエブサイトデータを線形ドキュメントに格納し、(6) 格納されたウエブサイトアドレス情報にあるアドレスすべてがア

クセスされてしまうまで、 $(1) \sim (5)$  の処理を繰り返し、フォーマット情報に基づいて線形ドキュメントを

個人化ドキュメントの形にフォーマットする。



【特許請求の範囲】

【請求項1】 少なくとも1つのハイパー・メディア・ドキュメントからデータをフォーマットする方法であって、

少なくとも1つのハイパー・メディア・ドキュメントに アクセスするアクセス工程と、

前記ハイパー・メディア・ドキュメントからデータを、 前記ハイパー・メディア・ドキュメントの構造に基づい て、抽出データ・ツリーへと取り出す取出し工程と、

この抽出データ・ツリーを線形ドキュメントに平坦化す 10 るための平坦化工程と、

その線形ドキュメントをフォーマット化されたドキュメントにフォーマットするためのフォーマット工程ととを 具備することを特徴とするデータフォーマット方法。

【請求項2】 そのフォーマットされたドキュメントを プリントする工程をさらに具備することを特徴とする請 求項1に記載のデータフォーマット方法。

【請求項3】 前記ハイパー・メディア・ドキュメント はワールド・ワイド・ウエブに置かれることを特徴とす る請求項1に記載のデータフォーマット方法。

【請求項4】 前記ハイパー・メディア・ドキュメントはインターネットに置かれることを特徴とする請求項1に記載のデータフォーマット方法。

【請求項5】 前記ハイパー・メディア・ドキュメントはイントラネットに置かれることを特徴とする請求項1に記載のデータフォーマット方法。

【請求項6】 前記アクセス工程、前記取出し工程、前 記平坦化工程および前記フォーマット工程は個人用ニュ ース・プロファイルに従って実行されることを特徴とす る請求項1に記載のデータフォーマット方法。

【請求項7】 ハイパー・メディア・リンクのコンピューターネットワークからデータを抽出するための個人用ニュース・プロファイルを創成する創成方法であって、ハイパー・メディア・リンクのコンピューターネットワークにアクセスする工程と、

学習モードを入力する工程と、

コマンドによって前記ハイパー・メディア・リンクのコンピューターネットワーク上のサイトを横断する工程と、

そのコマンドから少なくとも1つの規則を抽出する工程 40 と.

その少なくとも1つの規則を個人用ニュース・プロファイルにまとめるコンパイル工程とを具備することを特徴とするプロファイル創成方法。

【請求項8】 前記少なくとも1つの規則は、前記ハイパー・メディア・リンクのコンピューターネットワークを横断するために、サイトの構造的な特徴を指定することを特徴とする請求項7のプロファイル創成方法。

【請求項9】 前記少なくとも1つの規則は、前記ハイパー・メディア・リンクのコンピューターネットワーク 50

を横断するために、内容に基づく基準を指定することを 特徴とする請求項8のプロファイル創成方法。

【請求項10】 ウエブサイト検索データ検索システム のための個人化プロファイルを創成するための個人化システムであって、

ワールド・ワイド・ウエブにアクセスするために、データおよびコマンドを入力するための入力部と、

前記ワールド・ワイド・ウエブとの接続部と、

前記個人化システムからのコマンドに従って、前記ワールド・ワイド・ウエブとの前記接続部を介して前記ワールド・ワイド・ウエブにアクセスするためのウエブ・リーダを格納するためのメモリと、

ユーザのコマンドに応答して個人化システムを起動する ためのプロセッサとを具備し、

前記個人化システムは、起動されると、(1)ウエブ・リーダを起動し、(2)ウエブ・リーダを通じてワールド・ワイド・ウエブにアクセスし、(3)学習モードを入力し、(4)ユーザコマンドに従ってワールド・ワイド・ウエブを横断するように前記ウエブ・リーダに命令を送り、(5)そのユーザコマンドから少なくとも1つの規則を抽出し、(6)その少なくとも1つの規則を個人化プロファイルにまとめ、(7)その個人化プロファイルを格納することを特徴とする個人化システム。

【請求項11】 ハイパー・メディア・リンクのコンピューターネットワークから記事を検索し、その記事を個人化された新聞の形にフォーマットするための方法であって、

前記ハイパー・メディア・リンクのコンピューターネットワーク上のサイトを示すアドレスデータと、そのサイトからデータにアクセスするためのコマンドデータと、 新聞レイアウトコマンドとを有する格納された個人用ニュース・プロファイルを取り出す工程と、

その個人用ニュース・プロファイルに格納されるアドレスデータに基づいて前記サイトに連絡をとる工程と、前記個人用ニュース・プロファイルに格納されるコマンドデータに基づいてそのサイトから記事をダウンロードするための工程と、

その記事を線形ドキュメントの形に平坦化する工程と、 前記線形ドキュメントを、前記個人用ニュース・プロフ アイルに格納されたレイアウトコマンドに従って個人化 された新聞の形にフォーマットする工程とからを具備す ることを特徴とする記事記事取出しフォーマット方法。

【請求項12】 その個人化された新聞をプリントする 工程を具備することを特徴とする請求項11に記載の記 事取出しフォーマット方法。

【請求項13】 前記ハイパー・メディア・リンクのコンピューターネットワークはワールド・ワイド・ウエブであることを特徴とする請求項11に記載の記事取出しフォーマット方法。

【請求項14】 前記ハイパー・メディア・リンクのコ

\_

ンピューターネットワークはインターネット上にあることを特徴とする請求項11に記載の記事取出しフォーマット方法。

【請求項15】 前記ハイパー・メディア・リンクのコンピューターネットワークはイントラネット上にあることを特徴とする請求項11に記載の記事取出しフォーマット方法。

【請求項16】 データにアクセスするための前記コマンドデータは、サイトの構造に基づいて記事を選択するためのデータを含むことを特徴とする請求項11に記載 10の記事取出しフォーマット方法。

【請求項17】 データにアクセスするための前記コマンドデータは、記事の内容に基づいて記事を選択するためのデータを含むことを特徴とする請求項16に記載の記事取出しフォーマット方法。

【請求項18】 少なくとも1つのウエブサイトにアクセスし、そのウエブサイトからデータを検索して取り出し、そのデータを個人化されたドキュメントの形にフォーマットする、ワールド・ワイド・ウエブ・サイト・データ検索システムであって、

ワールド・ワイド・ウエブにアクセスするためにデータ およびコマンドを入力するための入力部と、

ウエブ・リーダを含むウエブ・サイト・データ検索ドライバと、格納されたウエブサイトアドレス情報と、格納されたフォーマット情報とを格納するためのメモリであって、ウエブサイトに接続し、接続されたウエブサイトの中でコマンドを発行する工程を含むことを特徴とするメモリと、

ワールド・ワイド・ウエブと接続する接続部と、

ワールド・ワイド・ウェブにアクセスするためのコマンドを入力するユーザに応答してウエブ・サイト・データ取り出しドライバを起動するプロセッサであって、ウエブ・サイト・データ取り出しドライバは起動されると、

(1) ウエブ・リーダを起動して前記接続部を介してワ ールド・ワイド・ウエブに接続し、(2) ウエブサイト アドレス情報およびウエブサイトコマンドを検索して取 り出し、(3)このウエブサイトアドレス情報およびウ エブサイトコマンドに基づいて、ウエブサイトにアクセ スするように、ウエブ・リーダに命令し、(4)ループ を形成するハイパー・メディア・リンクを避け、そして 40 既にダウンロードされたデータを繰り返しダウンロード することを避けるために、リンクされたリストを参照し て前記ウエブサイトコマンドに基づいてウエブサイトか らウエブサイトデータをダウンロードし、(5) そのウ エブサイトデータを線形ドキュメントに格納し、(6) 格納されたウエブサイトアドレス情報にあるアドレスす べてがアクセスされてしまうまで、工程1から工程5ま でを繰り返し、前記フォーマット情報に基づいて前記線 形ドキュメントを個人化ドキュメントの形にフォーマッ トすることを特徴とするワールド・ワイド・ウエブ・サ 50 イト・データ検索システム。

【請求項19】 前記ウエブサイトアドレス情報、ウエブサイトコマンドおよびメモリに格納されたフォーマット情報は個人用ニュース・プロファイルを形成することを特徴とする請求項18に記載のウエブサイトデータ検索システム。

【請求項20】 更に個人化されたドキュメントをプリントするためのプリンタを具備することを特徴とする請求項18に記載のウエブサイトデータ検索システム。

【請求項21】 個人化されたドキュメントは個人化された新聞の型を示すことを特徴とする請求項18に記載のウエブサイトデータ検索システム。

【請求項22】 個人化されたドキュメントは個人化された雑誌の型を示すことを特徴とする請求項18に記載のウエブサイトデータ検索システム。

【請求項23】 個人化されたドキュメントは個人化された書籍の型を示すことを特徴とする請求項18に記載に記載のウエブサイトデータ検索システム。

【請求項24】 コンピューター読み取り媒体に格納されたコンピューター実行処理工程であって、ワールド・ワイド・ウエブサイトにアクセスし、サイトのデータを検索し、そのデータを個人化されたドキュメントの形にフォーマットする実効処理工程であって、

ワールド・ワイド・ウエブに接続する接続工程と、

ユーザ定義のウエブサイトアドレス情報、ユーザ定義のウエブサイトコマンド、およびユーザ定義のフォーマットコマンドを取り出すための取り出し工程と、ユーザ定義の前記ウエブサイトアドレス情報に基づいてウエブサイトにアクセスし、ユーザ定義の前記ウエブサイトコマンドに基づいてウエブサイト内からデータを検索するように、ウエブ・リーダを起動させるための起動工程と、アクセスされた前記ウエブサイトから取り出された前記ウエブサイトデータを、抽出データ・ツリーの形でにダウンロードするためのダウンロード工程と、

前記抽出データ・ツリーを線形ドキュメントの形に平坦 化するための平坦化工程と、

ユーザ定義の前記ウエブサイトアドレス情報にある全て のアドレスがアクセスされてしまうまで、ダウンロード 工程および平坦化工程を繰り返すための工程と、

ユーザ定義の前記フォーマットコマンドに従って、前記 格納されたデータを個人化されたドキュメントの形にフ オーマットするためのフォーマット工程とを具備するこ とを特徴とするコンピュータ実行可能処理工程。

【請求項25】 前記個人化されたドキュメントを出力 装置へスプールするためのスプール工程を具備すること を特徴とする請求項24に記載のコンピューター実行可 能処理工程。

【請求項26】 その出力装置はプリンタであることを 特徴とする請求項25に記載のコンピューター実行可能 処理工程。 【請求項27】 その出力装置はディスプレーであることを特徴とする請求項25に記載のコンピューター実行可能処理工程。

【請求項28】 ユーザ定義のウエブサイトコマンドは ウエブサイトの情報に基づいてデータを選択するための コマンドを含むことを特徴とする請求項24に記載のコ ンピューター実行可能処理工程。

【請求項29】 ユーザ定義のウエブサイトコマンドは ウエブサイトの内容に基づいてデータを選択するための コマンドを含むことを特徴とする請求項28に記載のコ ンピューター実行可能処理工程。

【請求項30】 ワールド・ワイド・ウエブ上のオンラインニュースサービスからニュース記事を検索して取出し、そのニュース記事を個人化された新聞の形にフォーマットするためのニュース検索装置であって、

(1) ウエブサイトからのデータにアクセスするための アドレスデータおよびコマンドデータと (2) 新聞フォ ーマットコマンドとを格納する第1の格納手段と、

格納された前記個人用ニュース・プロファイルを検索してそこに格納されたデータにアクセスするための検索取 20出し手段と.

前記個人用ニュース・プロファイルに格納されたアドレ スデータに基づいて、ウエブサイトに接続するべくウエ ブ・リーダを起動する起動手段と、

前記個人用ニュース・プロファイルに格納されたコマンドデータに基づいて、接続されたウエブサイトからニュース記事をダウンロードするダウンロード手段、

ダウンロードされた前記ニュース記事を格納する第2の 格納手段と、

前記個人用ニュース・プロファイルに格納された新聞フォーマット・コマンドに基づいて、格納された前記ニュース記事を個人化された新聞の形にフォーマットするためのフォーマット手段とを具備することを特徴とするニュース検索装置。

【請求項31】 更に、個人化された新聞をプリンタへスプールためのスプール手段を具備した請求項30に記載のニュース検索装置。

【請求項32】 データをハイパー・メディア・ドキュメントから個人化されたドキュメントにフォーマットするデータフォーマット方法であって、

前記ハイパー・メディア・ドキュメントの位置を指定するための位置指定工程と、

前記ハイパー・メディア・ドキュメントの型式を指定するための型式指定工程と、

ハイパー・メディア・ドキュメントの構造に基づいて決められた範囲であって、前記ハイパー・メディア・ドキュメントから検索するべきデータの前記範囲を指定する範囲指定工程と、

前記ハイパー・メディア・ドキュメントから取出された データを個人化されたドキュメントの形にフォーマット するためのフォーマットを指定するフォーマット指定工 程と、

前記位置指定工程で指定された位置で見つけられたハイパー・メディア・ドキュメントにアクセスするアクセス 工程と、

前記型式指定工程で指定された形式と前記範囲指定工程 で指定された範囲とに従ってデータを検索すべく、前記 アクセス工程でアクセスされたハイパー・メディア・ド キュメントから前記データを検索する検索工程と、

前記フォーマット指定工程で指定されたフォーマットに 従ってそのデータをフォーマットするべく、前記検索工 程で検索された前記データを個人化されたドキュメント の形にフォーマットするフォーマット工程とを具備する ことを特徴とするデータフォーマット方法。

【請求項33】 更に、個人化されたドキュメントをプリントするためのプリント工程を具備することを特徴とする請求項32に記載のデータフォーマット方法。

【請求項34】 前記位置指定工程で指定される位置は ファイル名であることを特徴とする請求項32に記載の データフォーマット方法。

【請求項35】 前記位置指定工程で指定される位置は、ワールド・ワイド・ウエブのためのユニフォーム・リソース・ロケータであることを特徴とする請求項32に記載のデータフォーマット方法。

【請求項36】 ハイパー・メディア・ドキュメントを 処理する処理方法であって、

前記ハイパー・メディア・ドキュメントにアクセスする 工程と、

前記前記ハイパー・メディア・ドキュメントからアドレスを抽出する工程と、

前記ハイパー・メディア・ドキュメントから抽出された アドレスをメモリの中のコンテナに格納する工程と、

前記コンテナに格納されたアドレスに格納されたデータ を処理するための処理機能を起動する工程と、

前記コンテナ内のアドレスに格納されたデータを前記メ モリヘダウンロードする工程と、

予め決定された構成情報に従って、ダウンロードされた 前記データから所定のデータを抽出する工程と、

予め定義されたフォーマット設定に従って、前記所定の データをフォーマットし、フォーマットされたドキュメ ントを生成するフォーマットする工程と、

前記処理機能に従ってフォーマットされたドキュメント を処理する工程とを具備することを特徴とするドキュメ ント処理方法。

【請求項37】 更に、フォーマットされたドキュメントを処理する前に、フォーマットされたドキュメントをプレビューする工程を具備することを特徴とする請求項36に記載のドキュメント処理方法。

【請求項38】 更に、ドキュメントをプレビューした 後であって、フォーマットされたドキュメントを処理機

6

10

能に従って処理する前において、フォーマットの設定を 変更する工程と、

前記処理機能を再起動する工程と、

フォーマットされたドキュメントを生成するために、変 更されたフォーマットの設定に従ってデータを再フォー マットする工程とを具備することを特徴とする請求項3 7に記載のドキュメント処理方法。

【請求項39】 前記アドレスが前記コンテナに入力される順序に従って、前記アドレスが前記コンテナに格納され、

そのアドレスがコンテナに格納される順序に従って、予め決定されるデータを処理機能が処理することを特徴とする請求項36に記載のドキュメント処理方法。

【請求項40】 更に、コンテナ内のアドレスをドラッグおよびドロップすることにより、コンテナに格納されるアドレスを再配列する工程を具備することを特徴とする請求項39に記載のドキュメント処理方法。

【請求項41】 更に、フォーマットの設定および構成情報をグラフィック・ユーザ・インターフェースを通して入力する工程を具備することを特徴とする請求項36に記載のドキュメント処理方法。

【請求項42】 グラフィック・ユーザ・インターフェースは、その1つが処理機能を起動する複数の処理アイコンを有することを特徴とする請求項41に記載のドキュメント処理方法。

【請求項43】 グラフィック・ユーザ・インターフェースは複数のモードで表示されることを特徴とする請求項42に記載のドキュメント処理方法。

【請求項44】 前記複数のモードは、(1) 前記グラフィック・ユーザ・インターフェースが、フォーマット 30 するフィールドと、処理オプションと、メニューと、上記処理のアイコンとを表示するフル機能モードと、

(2) 前記グラフィック・ユーザ・インターフェースが 前記処理アイコンのみを表示する最小化モードとを有す ることを特徴とする請求項43に記載のドキュメント処 理方法。

【請求項45】 前記最小化モードにあるグラフィック・ユーザ・インターフェースは、ハイパー・メディア・ドキュメントをブラウジングする間に表示されることを特徴とする請求項44に記載のドキュメント処理方法。

【請求項46】 ハイパー・メディア・ドキュメントを 処理する処理装置であって、

前記ハイパー・メディア・ドキュメントにアクセスする ウエブ・リーダと、

前記ハイパー・メディア・ドキュメントからアドレスを 抽出する手段と、

前記ハイパー・メディア・ドキュメントから抽出された アドレスを格納するコンテナを含むメモリと、

コンテナに格納されたアドレスに格納されたデータを処理するために、少なくとも1つの処理機能を起動する処 50

理アイコンを有するグラフィック・ユーザ・インターフェースと、

(1)前記コンテナに格納されたアドレスに格納されたデータをメモリへダウンロードし、(2)予め定義された構成の設定に従って、ダウンロードされた前記データから所定のデータを抽出し、(3)フォーマットされたドキュメントを生成させるための予め定義されたフォーマットの設定に従って前記所定のデータをフォーマットし、(4)前記処理機能に従ってフォーマットされたドキュメントを処理する処理手段と、を具備することを特徴とするドキュメント処理装置。

【請求項47】 更に、フォーマットされたドキュメントを処理する前に、フォーマットされたドキュメントをプレビューするプレビュー手段とを具備することを特徴とする請求項46に記載のドキュメント処理装置。

【請求項48】 アドレスがコンテナに入力された順序 に従って前記アドレスがコンテナに格納され、

前記アドレスが前記コンテナに格納された順序に従って、前記所定のデータを前記処理機能が処理することを 特徴とする請求項46に記載のドキュメント処理装置。

【請求項49】 更に、前記コンテナにあるアドレスを再配列するために、前記コンテナでリストされたアドレスをドラッグおよびドロップするためのドラッグ・ドロップ手段を具備することを特徴とする請求項48に記載のドキュメント処理装置。

【請求項50】 更に、フォーマットの設定および構成情報をグラフィック・ユーザ・インターフェースを通して入力するための入力手段を具備することを特徴とする請求項46に記載のドキュメント処理装置。

【請求項51】 グラフィック・ユーザ・インターフェースは、その1つが処理機能を起動する複数の処理アイコンを具備することを特徴とする請求項50に記載のドキュメント処理装置。

【請求項52】 グラフィック・ユーザ・インターフェースを複数のモードで表示するための表示手段を具備することを特徴とする請求項51に記載のドキュメント処理装置。

【請求項53】 前記複数のモードは、

(1) 前記グラフィック・ユーザ・インターフェースが、フォーマットするフィールドと、処理オプションと、メニューと、上記処理のアイコンとを表示するフル機能モードと、(2) 前記グラフィック・ユーザ・インターフェースが前記処理アイコンのみを表示する最小化モードとを具備することを特徴とする請求項52に記載のドキュメント処理装置。

【請求項54】 最小化モードで表示されたグラフィック・ユーザ・インターフェースは、前記ハイパー・メディア・ドキュメントをブラウジングする間に表示されることを特徴とする請求項53に記載のドキュメント処理装置。

10

## 【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明は、コンピュータ・ネットワーク上のハイパー・メディア・ドキュメントを自動的に横断して、これらドキュメントから、そのドキュメントの構造とパーソナライズ(personalized)されたデータ検索構造との合致に基づいて、情報を自動的に検索するデータ検索システムに関する。より詳しくいうと、本発明は、ワールド・ワイド・ウエブ上の、あるいはハイパー・メディア・リンクをサポートする私的なコンピュータネットワーク上の、或いは、他のあらゆるハイパー・メディアでリンクされたコンピュータシステム上の、ニュースサービスから、あるいはマガジンサービスから、または両者を組み合わせたものから、記事を検索することができる。

【0002】たとえば、ニューヨークタイムズ(New Yor k Times)からニュース記事を検索するためのウエブサイ トや、雑誌ピープル(People)から記事を検索するウエブ ・サイトが存在する。本発明の検索システムは、このよ うなウエブサイトを横断し、パーソナライズされたデー 20 タ検索構造に基づいて記事を選択することができる。こ の個人化データ検索構造は、第1面のみの、ビジネス欄 のヘッディングの、株式欄の、スポーツ欄等のヘッディ ングの全文を検索するように命令するコマンドを含むこ ともできる。さらに、この個人化データ検索構造は、コ ンテント依存型ルール(content-based rules)を含むこ とができ、あるキーワードを有する記事を検索し、ある 類は、あるキーワードを有する記事を除外し、あるい は、ある規則に基づく内容分析に基づいた記事を含むこ ともできる。本発明は、また、検索したニュース記事す べてを統合し、その統合したニュース記事を、その記事 の各々がユーザが予め定義したレイアウトに基づいて配 置されるような、新聞型のフォーマットで印刷するため の方法を提供する。

【0003】上記の例はWWウエブに関連するものだが、ハイパー・メディア・ドキュメントはウエブだけでなく、イントラネットのような他の型のネットワークにも存在することができる。イントラネットは外部のコンピュータネットワークに接続しない私的なコンピュータネットワークである。たとえば会社所有のコンピュータネットワークはハイパー・メディア・ドキュメントを内蔵するイントラネットになることができる。要するに、以下の議論はワールド・ワイド・ウエブに関して行われるものである。しかしながら本発明は、ハイパー・メディア・ドキュメントを容れるあらゆるタイプのコンピュータネットワーク(例えば、イントラネット、あるいはインターネット上のWWウエブ以外のハイパー・メディア・リンクのコンピュータ・ネットワーク)にも等しく良好に適合することが理解されよう。

【0004】₩Wウエブ上のハイパー・メディア・ドキュ 50

メントは、複数のウエブ・サイトにまたがることができる。このようなドキュメントには、新聞、新聞記事、雑誌、カタログ、マニュアル、覚書、その他同種のものが可能である。要するに、これから行われる議論はニュース情報のソースに関して行われるものである。しかし、本発明はハイパー・メディア・ドキュメントのいずれの型にも、等しく良好に適合することが理解されよう。

[0005]

【従来の技術】ワールド・ワイド・ウエブ(WWウエブ)とはハイパー・メディア・ドキュメントのオンラインのソースであって、ハイパー・メディア・ドキュメントは、ウエブサイトなど、他のドキュメントやウエブサイト等へのリンクとして機能するハイパー・メディア・テキストとハイパー・メディア・イメージとを有する。従って、WWウエブ上のドキュメントは連続的に構成されない。むしろ、ユーザは他のドキュメントまたはウエブ・サイトに自動的にリンクされるのであって、ドキュメント内にあるテキストリンクやイメージリンクのようなハイパー・メディア・リンクを選択することによって、ドキュメント全体を見ることができる。従って、ドキュメント全体を見ることができる。だって、ドキュメント全体はテキストをスクロールしても見ることができない。

【0006】このウエブの一般的な使い方のひとつは、雑誌および新聞のオンラインでの発行および発信である。最近では、ニューヨークタイムズ等の多くのウエブ・ニュース・サービスが、ユーザが関心事についてのキーワードを定め、キーワードに合うテキストを有するニュース情報を時々刻々受け取れるようにしている。それで、ニュース情報はユーザのコンピュータにモデムやEメールを通じて送られる。しかし、ニューヨークタイムズのような、ほとんどのウエブ・ニュース・サイトの新聞は、含む情報が多すぎるために、しかもその情報がキーワードの合致によってのみ検索されるために、そのほとんどがユーザにとって無関係のものである。

【0007】ニュース情報のソースは、そのほか、"イ ンディビデュアル・インクIndividual Inc." のような 情報提供者により提供される。インディビデュアル・イ ンクは、ユーザにより予め定められたキーワードに基づ いて、もっとも関連性の強い上位二十の記事の短い要約 をユーザに提供する。この予約購読制のニュース・サー ビスは、ユーザがキーワードに基づいて重要度の範囲を 五から十までに仕分けして、それに優先順位をつけるこ とができるようにする。この情報サービスは、それらの キーワードのいずれかを有する雑誌と新聞を求めてWWウ エブを探索する。そのキーワード検索に基づいて、もっ とも関連性の強い記事のうち二十が選び出され、1頁の 短い要約にまとめられて、ユーザに提供するためにファ クシミリでユーザへ送られる。しかしユーザが、要約で はなくてドキュメント全体を見るためには、そのドキュ メントを含む特定のウエブサイトにログオンして、その

ドキュメントを検索しなければならない。

【0008】ユーザが新聞を個人化(personalize)して 端末画面に表示させることできるようにするサービスが ほかにもまだあり、それは、ウエブ上の種々のニュース ・ソースから種々のニュース記事へのリンクを格納する ことによって可能である。たとえばCRAYON (Create You r Own Newspaper)は、ユーザが、25以上の異なるオン ライン新聞へのリンクの中から特定のセクションを選択 して、その選択を個人化された新聞に構成することがで きるようにするものである。CRAYONを使用すれば、たと えばニューヨーク・タイムズの国際関係欄、ウオール・ ストリート・ジャーナルのビジネス欄、シカゴ・トリビ ューンのスポーツ欄へのリンクを有する個人化された新 聞を構成することができる。その後、この新聞のための HTML(hypertext markup language)ソース・ファイル は、後で使用するためのマス・メディア・ストレージに 格納される。

#### [0009]

【発明が解決しようとする課題】前述のニュース・サービスや情報サービスが、ニュースを最新のものに保つための便利な方法を提供するとしても、人が現実世界の新聞を自然に読むような方法で、ユーザがニュースにアクセスできたり、見たりすることはできるようにするものでない。即ち、人は、おもしろいと思う欄のページを走り読みした後で、自分の注意がひかれた記事を読むことによって、自然にニュースを読むのである。換言すると、人は、構造的な入り方をするもので、初めにどのページ(たとえばビジネス欄、世界欄の一ページ目、そして芸術欄のコミックのページ)を読むかを決める。それから、選択したページ内で記事を選択するのである。

【0010】要するに、従来のニュース・情報サービスでは、ユーザは、ハイパー・メディア・ドキュメントからデータに、そのドキュメントの構造に基づいてアクセスすることはできず、さらにユーザが、そのデータを自然にスキャンし読むことができるように、そのデータをフォーマットすることができない。

## [0011]

【課題を解決するための手段】本発明は当該技術における上述の問題点の解決に向けられたもので、少なくともひとつのハイパー・メディア・ドキュメントにアクセスし、次に、そのハイパー・メディア・ドキュメントからデータを抜き出してデータ・ツリーに組み入れ(この場合、そのデータは、前記ハイパー・メディア・ドキュメントの構造に基づいて検索される)、さらにその抜き出されたデータ・ツリーを線形(linear)のドキュメントの形に平坦化し、そしてその線形のドキュメントを定型のドキュメントの形にフォーマットすることによりなされる。

【0012】別の面において、本発明は、ハイパー・メディア・リンクのコンピュータ・ネットワークからデー 50

タを検索するための、個人用ニュース・プロファイルを 作るものである。先ず、そのハイパー・メディア・リン クのコンピュータネットワークがアクセスされ、学習モードが開始され、ハイパー・メディア・リンクのコンピュータネットワークはコマンドで横断され、少なくとも 1個の規則がそのコマンドから抜き出され、そしてその 規則は個人用ニュース・プロファイルの形にまとめられる。

12

【0013】さらに別の面において、本発明はウエブサイト検索・データ検索システムのための、個人化プロファイルを作るものである。データとモードがワールド・ワイド・ウエブにアクセスするために入力され、ワールド・ワイド・ウエブとのコネクションが作られる。ウエブ・リーダが起動され、このウエブ・リーダがコネクションを通して、ウエブにアクセスする。ユーザコマンドに応答して、学習モードが開始される。ワールド・ワイド・ウエブをトラバースするためにコマンドが送られ、このコマンドから、少なくともひとつの規則が抽出される。この規則は個人化プロファイルにまとめられ、この個人化ファイルは格納される。

【0014】さらに別の面において、本発明は、ハイパ ー・メディアにリンクしたコンピュータネットワークか ら記事を検索して、その記事を個人化された新聞にフォ ーマットするものである。格納された個人用ニュース・ プロファイルが検索される。この個人用ニュース・プロ ファイルはハイパー・メディア・リンクのコンピュータ ネットワーク上のサイトのアドレスデータ、このサイト からデータをアクセスするためのコマンドデータ、およ び新聞レイアウトコマンドを含む。このサイトは個人用 ニュース・プロファイルに格納されるアドレスデータに 基づいてアクセスされ、そしてサイトの記事は、個人用 ニュース・プロファイルに格納されるコマンド・データ に基づいてダウンロードされる。そのダウンロードされ た記事は線形ドキュメントの形に平坦化され、この線形 ドキュメントは、個人用ニュース・プロファイルに格納 される新聞・レイアウト・コマンドに従って、個人化さ れた新聞の形にフォーマットされる。

【0015】さらに別の面において、本発明は、ワールド・ワイド・ウエブのサイトからデータを検索し、そのデータを、個人化されたドキュメントの形にフォーマットするものである。ウエブ・リーダと、格納されたウエブサイト・アドレス情報と、格納されたウエブサイト・データ検索ドライバーがアクセスされる。本発明は、(1)ワールド・ワイド・ウエブに、このウエブとのコネクションを通じて接続するために、ウエブ・リーダを開始し、(2)ウエブサイト・アドレス情報ならびにウエブサイト・コマンドを検索し、(3)ウエブサイト・アドレス情報ならびにウエブサイト・コマンドに基づいてウエブ・サイトにアクセスするため

に、ウエブ・リーダに命令し、(4)ループを形成するハイパー・メディア・リンクを避けるように、そしてダウンロード済みのデータを繰返しダウンロードしないように、リンクされたリストに参照してデータをダウンロードするように命令するウエブサイト・コマンドに基づいて、ウエブサイトからウエブサイト・データを線形ドキュメントに格納し、(6)格納されたウエブサイト・アドレス情報にあるアドレスがすべてアクセスされてしまうまで、工程(2)から工程(5)までを繰り返し、そして(7)フォーマット情報に基づいて、線形ドキュメントを個人化されたドキュメントの形にフォーマットする。

【0016】さらに別の面において、本発明は、ワール ド・ワイド・ウエブ・サイトにあるデータにアクセス し、検索し、そのデータを個人化されたドキュメントの 形にフォーマットするものである。本発明はワールド・ ワイド・ウエブに接続し、ユーザが定義したウエブサイ ト・アドレス情報、ユーザが定義したウエブサイト・コ マンド、ユーザが定義したフォーマット・コマンドを検 20 索し、このユーザが定義するウエブサイト・アドレス情 報に基づいてウエブサイトにアクセスするように、ウエ ブ・リーダを起動する。このウエブ・リーダは、ユーザ が定義するウエブ・サイト・コマンドに基づいて、デー タをウエブからダウンロードするために使われ、そして そのデータは抽出されたデータ・ツリーのなかヘダウン ロードされる。ユーザが定義するウエブサイト・アドレ ス情報にある全てのアドレスがアクセスされてしまうま で、このダウンロードは続く。抽出されたデータ・ツリ ーは線形ドキュメントの形で平坦化され、そしてこの平 30 坦化されたドキュメントは、ユーザが定義したフォーマ ット・コマンドに基づいて個人化されたドキュメントの 形にフォーマットされる。

【0017】さらに別の面において、本発明は、ワール ド・ワイド・ウエブ上のオンライン・ニュース・サービ スから、ニュース記事を検索し、そのニュース記事を個 人化された新聞の形にフォーマットするものである。本 発明は、ウエブサイトからのデータにアクセスするため の、アドレス・データおよびコマンド・データ、ならび に新聞フォーマット・コマンドからなる個人用ニュース 40 ・プロファイルを格納し、その格納された個人用ニュー ス・プロファイルを検索して、そこに格納されたデータ にアクセスし、個人用ニュース・プロファイルに格納さ れたアドレス・データに基づいて、ウエブ・サイトにコ ンタクトするように、ウエブ・リーダを起動し、個人用 ニュース・プロファイルに格納されたコマンド・データ に基づいて、コンタクトされたウエブ・サイトでニュー スをダウンロードし、そのダウン・ロードされたニュー ス記事を格納し、その格納された新聞記事を、個人用ニ ュース・プロファイルに格納された新聞フォーマット・

コマンドに基づいて、個人化された新聞の形にフォーマットする。

【0018】さらに別の面において、本発明は、ハイパ ー・メディア・ドキュメントを、個人化されたドキュメ ントの形にフォーマットするものである。ハイパー・メ ディア・ドキュメントの位置が指定され、ハイパーメデ ア・ドキュメントの型が指定され、ハイパー・メディア ・ドキュメントから検索すべきデータの領域が、ハイパ ー・メディア・ドキュメントの構造に基づくように指定 され、そしてフォーマットが、ハイパー・メディア・ド キュメントから検索されるデータを、個人化されたドキ ュメントの形にフォーマットするために指定される。そ の指定された位置で見つけられたハイパー・メディア・ ドキュメントはアクセスされ、データは、指定されたハ イパー・メディア・ドキュメントの型および指定された 範囲に従って、ハイパー・メディア・ドキュメントから 検索され、そしてそのデータは指定されたフォーマット に従って個人化されたドキュメントの形にフォーマット される。

【0019】さらに別の面において、本発明はハイパー ・メディア・ドキュメントを処理するためのシステムで ある。このシステムはハイパー・メディア・ドキュメン トにアクセスし、ハイパー・メディア・ドキュメントか ちアドレスを抜き出し、ハイパー・メディア・ドキュメ ントから抽出されたアドレスをコンテナに格納する。こ のシステムは、コンテナに格納されたアドレスで格納さ れたデータを処理するために、処理ファンクションを起 動し、コンテナに格納されたアドレスで格納されたデー タを、メモリヘダウンロードし、そして予め決定される データを、ダウンロードされたデータから、予め決定さ れる形状情報に従って抜き出す。その予め決定されるデ ータはそれから、フォーマットされたドキュメントを生 成させるために、予め定義されるフォーマットの設定に 従ってフォーマットされ、そしてこのフォーマットされ たドキュメントは処理ファンクションに従って処理され

【0020】好適な実施形態において、このシステムは、グラフィック・ユーザ・インターフェースを通して、フォーマットの設定および形状情報を入力するものである。このグラフィック・ユーザ・インターフェースは、複数あって、そのうちの1個が処理ファンクションを起動する処理アイコンから成る。グラフィック・ユーザ・インターフェースの能力により、ユーザはドキュメントのフォーマットを対話式に設定することと、そのフォーマットを、必要な場合に変更することができる。特に好適な実施形態において、グラフィック・ユーザ・インターフェースは、複数のモードで表示される。その複数のモードは、(1)グラフィック・ユーザ・インターフェースが、フォーマットする領域、処理オプション、メニューおよび処理アイコンを画面表示するようなフル

機能モード、並びに (2) グラフィック・ユーザ・インターフェースが処理アイコンだけを画面表示するような最小モードから成る。一般的には、最小モードで画面表示されたグラフィック・ユーザ・インターフェースは、ハイパー・メディア・ドキュメントをブラウジングしている間、画面表示される。本発明は、複数のモードでグラフィック・ユーザ・インターフェースを画面表示することにより、ハイパー・メディア・ドキュメントのブラウジングの間、本発明の作業を容易にする。

【0021】この要約は、本発明が速やかに理解されるように提供されるものである。その好適な実施形態についての詳細な説明を、添付の図面と関連させて参照することによって、本発明についてのより完全な理解が得られよう。

## [0022]

【発明の実施の形態】第1図は本発明の具体的な実施形態の外観を表わす展望図である。第1図では、マッキントッシュ、或いはIBMパソコン、或いはマイクロソフト・ウインドウズ等のウインドウ画面を有するPC互換コンピュータのような、コンピュータ装置1が説明される。コンピュータ装置1には、カラーモニターかモノクロモニターのようなディスプレー画面2、テキスト・データおよびユーザ・コマンドを打ち込むためのキーボード3、そして、ディスプレー2に表示されるオブジェクトを指示したり操作するためのマウス4のようなポインティング手段が設けられている。

【0023】コンピュータ装置1は、また、ディスクドライブ5のような大量記憶手段を含む。画像データは、ネットワーク・インターフェース11aのような種々のソースから、またはファクシミリやモデムのインターフ 30ェース6を通じて外部の手段から、コンピュータ装置1に入力することができる。ネットワーク・インターフェース11aは、コンピュータ装置1を、ローカルエリアネットワーク(LAN)に、またはワールド・ワイド・ウエブのようなワイドエリアネットワーク(WAN)に接続するために使用される。

【0024】第2図は、コンピュータ装置1の内部構造を示す詳細なブロック図である。第2図に示されるように、コンピュータ装置1は、コンピュータ・バス9に接続される中央処理ユニット(CPU)8を含む。プリン 40 タ・インターフェース10、ファクス/モデムインターフェース6、ディスプレイ・インターフェース11、ネットワーク・インターフェース11a、キーボード・インターフェース12、マウス・インターフェース13、メイン・メモリ14、ならびにディスクドライブ5もまたそれぞれコンピュータ・バス9に接続される。

【0025】メインメモリ14は、個人用ニュース・プロファイル・エディタ16またはウエブ・プリンタ17のようなアプリケーションを実行するときに、CPU8により使用されるためのランダム・アクセス・メモリ・

格納を提供するように、コンピュータ・バス9とやり取りする。より詳しく言うと、CPU8はこれらソフトウエア・アプリケーションを、ディスクドライブ5から、メイン・メモリ14へロードし、そしてそのソフトウエア・アプリケーションを、メイン・メモリ14上で実行する。ユーザの命令に従って、格納されたアプリケーション・プログラムは起動されデータの処理と操作を行

16

う。典型的には、個人用ニュース・プロファイル・エディタ16、ウエブ・プリンタ17、HTMLフォーマッタ18のようなソフトウエア・アプリケーションは、フロッピーディスクやCDROMのようなコンピュータ読み取り媒体からソフトウエア・アプリケーションをダウンロードすることにより、またはコンピュータ掲示板からソフトウエア・アプリケーションをダウンロードすることにより、ディスクドライブ5に格納されている。

【0026】ディスクドライブ5は、テキスト・ファイルおよび画像ファイルを含むことのできるデータファイルを圧縮フォーマットまたは非圧縮フォーマットで格納し、そして上記のようなソフトウエア・アプリケーション・ファイルを格納する。そのソフトウエア・アプリケーション・ファイルは、ウインドウズ・アプリケーション、DOSアプリケーション、および個人用ニュース検索ファイル15を含む。個人用ニュース検索ファイル15は、個人用ニュース・プロファイル・エディタ16、ウエブ・プリンタ17、HTMLフォーマッタ18、個人用ニュース・プロファイル19およびサイト・プロファイル20を含む。個人用ニュース検索ファイル15の詳細な機能は、個人用ニュース検索システムの作業を簡単に概観した後、説明されよう。

【0027】〈ドキュメント検索の概観〉第3図は第3 A図から第3D図までの図から成っており、本発明の具体的な実施形態の実行を図示する。第3A図は、ニュース情報を含む典型的なウエブ・サイト21を図示したものである。ウエブ・サイト21の中にはヘッディング23のようなインデックスへのリンクを有するホームページ22があり、このインデックスは次に記事24にリンクされる。記事24のあるものは他の記事にリンクされる。記事H26はもうひとつのウエブ・サイト上にあるので、リンク25はサイト横断リンクである。リンク25は、ホームページ22に代表される1つのハイパー・メディア・ドキュメントがどのように複数のウエブ・サイトを横断できるのかを説明する。

【0028】ニュースをウエブ・サイト21から検索するために、本発明は、最初にウエブ・サイト21を横断し、ユーザの定義した規則に従ってデータを検索する。これからより詳細に説明されるが、これらの規則はウエブ・サイト21の構造に、またはウエブ・サイト21の構造とそれの内容に基づくことができる。そのデータは抽出データ・ツリーの形に抜き出され、このツリーは、第3B図に示すようなデータの構成を保持する。尚、同

図において、いくつかのリンクは除外されている。

【0029】抽出データ・ツリー27の構成はいくつかの特徴を有する。その第1として、抽出データ・ツリー27は、サイト29のための1つ以上の子供ノードを有することのできるルート28を有する。このノードは、更に、インデックス/ヘッディング23や記事ノード31などに対応するインデックスノード30を次々に有することのできる。第2に、抽出データ・ツリー27は、いかなるループ(たとえば循環パス)も有しない真のツリーである。たとえば第3A図では、ホームページ22 10から、インデックス・ノード#1まで、次に記事Cまで、それからホームページ22に戻るループを図示するが、このループは抽出データ・ツリー27を作るときに除去される。

【0030】第2として、抽出データ・ツリー27の構成は、そのウエブ・サイトがどのようにトラバースされるかに依存するのであって、ウエブ・サイトの実際のレイアウトには依存しない。従って、記事H26はインデックス・ノード#3の下に(サイト#1の下に)現れており、このことは、本ニュース検索システムがサイト#1からサイト横断リンク25を通じて記事H26にアクセスしたことを示す。

【0031】最後に、先に言及したことであるが、ある記事は、ウエブ・サイト21の構造のために、あるいはインデックス/ヘッディング23と記事24の内容のために、データ・ツリー27から除外されている。たとえば記事EとGは、抽出データ・ツリー27から除外されている。本発明によると、抽出データ・ツリー27は、もっと多くの除外規則を参照する必要もあるが、第3C図で説明されているような線形ドキュメント32に平坦化される。線形ドキュメント32は、そこに埋め込まれた抽出データ・ツリー27からの情報を有するところの、単純に連続的なドキュメントである。

【0032】最後に、線形ドキュメント32は、ユーザの指定した(即ちデフォルト)フォーマット化指令に従って、第3D図で様式化された個人用新聞として説明される、フォーマットされたドキュメント33の形に定式化される。このフォーマットされたドキュメント33は、サイトのラベル、インデックス/ヘッディング、記事などについて、さまざまなフォントおよび色(または40いずれか一方)を有する。さらに、フォーマットされたドキュメント33はページに分割される。

【0033】本ニュース検索システムの別の実施形態において、上述した、ウエブ・サイト21からフォーマット化ドキュメント33までの変換のある段階をスキップすることができる。たとえば、ウエブ・サイト21からのデータは、同じ記事を二回ダウンロードせずにそしてウエブ・サイト21の構成においてループを避けるために、そのデータの構成のレコードが維持され(あるいは別のリンクされたリストにおいて)る限りにおいて、平50

坦化されたドキュメント32の形式に直接に検索することができる。別の実施形態では、抽出データ・ツリー27は、フォーマットされたドキュメント33の形に、直接フォーマットできる。いずれにせよ、本発明の基本的な動作は同じであり、即ち、本ニュース検索システムは、ウエブ上のハイパー・メディア・ドキュメントを横断して、ユーザが定義する情報に従ってデータを抜き出し、そのデータを個人化された新聞の形にフォーマットする。

【0034】上記議論で述べたように、種々のユーザ定義規則および他の情報(フォーマット情報のような)が本ニュース検索の処理に使われる。そのユーザ定義情報は、個人用ニュース・プロファイル19に格納され、その定義は次に説明される。

〈個人用ニュース・プロファイルの定義〉第4図および第5図は、個人用ニュース・プロファイル19が定義される処理を図示する。個人用ニュース・プロファイル19を作るために、個人用ニュース・プロファイル・エディタ16は個人用ニュース・プロファイル19、サイト・プロファイル20およびウエブ・リーダ34と連絡を取る。

【0035】個人用ニュース・プロファイル19は、個人化された新聞を作るためにどのサイトにアクセスすべきか、それらのサイトからどの部門を検索すべきかに関する情報、その部門からどのデータを抜き出すかを決定するために使用される規則、どのようにリンクを除外するかを決定するための規則および新聞フォーマット情報を有する。個人用ニュース・プロファイルの実例が付録1で説明される。

【0036】サイト・プロファイル20は、特定のユー ザに特定されない一般的なサイト情報を含む。たとえ ば、サイト・プロファイル20は、十分なサイト・アド レス、サイト内のセクション、ユーザに特定されないパ スワード等のような情報を含むことできる。サイト・プ ロファイルの実例が付録1で説明される。一般的なサイ ト情報はサイト・プロファイル20に格納されているの で、個人用ニュース・プロファイル19は、サイト・プ ロファイル20を参照しながら、その一般的なサイト情 報を参照し、そのために、個人用ニュース・プロファイ ルのスペースを節約することができる。たとえば付録1 で説明されるように、個人用ニュース・プロファイル1 9はサイト番号1を参照することができる。サイト・プ ロファイル20は、サイト番号1が"http//www.sjmercu ry.com/"にホームページを有する"サンノゼ・マーキュ リー・ニュース"であるということを示す。この構造 は、また、一般的なサイト情報を中央に集める。従って サイト・アドレスが変わると、このシステム上の全ての 個人用ニュース・プロファイル19を最新のものにする ために、サイト・プロファイル20だけは変更される必 要がある。

【0037】ウエブ・リーダ34は、ウエブ・サーバー35を介してWWウエブと通信するアプリケーション・プログラム即ちプログラム・モジュールである。ウエブ・リーダ34は、個人用ニュース・プロファイル・エディタ16からのコマンドに応答してWWウエブにアクセスし、ウエブ上のハイパー・メディア・ドキュメントを横断し、このドキュメントからデータを検索し、そして検索されたデータを個人用ニュース・プロファイル・エディタ16に戻す。

【0038】第4図で説明されたように、個人用ニュー 10 ス・プロファイル・エディタ16は、サイト・ドライバ ー36、ウエブ・リーダ・インターフェース37、プロ ファイル・マネージャ38およびフォーマット・エディ タ39の、4個のモジュールを含む。ウエブ・リーダ・ インターフェース37は、個人用ニュース・プロファイ ル・エディタ16をウエブ・リーダ34にインターフェ ースさせる。サイト・ドライバー36は、ウエブ・リー ダ・インターフェース37を通じてウエブ・リーダ34 と対話して、個々のウエブ・サイトそれぞれに対してア ブストラクト インターフェースを提供する。より詳細 20 にいうと、サイト・ドライバー36は、ウエブ・リーダ 34に指令して、いろいろなウエブ・サイトにアクセス せしめ、それらのサイトからデータを検索させる。その 後は、サイト・ドライバー36は、そのデータを受け取 り、そこからサイト・プロファイル20を組み立てる。 そのデータは、また、現存のサイト・プロファイルを最 新のものにするために使用することができる。

【0039】サイト・ドライバー36は、サイト・プロファイル20を組み立てる時に、それぞれアクセスされたウエブ・サイトの構造を、サイト・プロファイル20で定義された均一の構造に変換し、そこから検索されたデータをサイト・プロファイル20に格納する。本発明は、別々のウエブ・サイト(それのあるものは異なる構造を有するかもしれない)をひとつの均一な構造に変換し、そしてウエブ・サイトからのデータをサイト・プロファイル20のその構造に格納することによって、異なるウエブ・サイトからの情報へのアクセスを容易にし、従って全体の処理時間を少なくする。

【0040】プロファイル・マネージャ38は、個人化された新聞をどのようにフォーマットするかを指定するドキュメント・テンプレートを管理する。予め定義されたドキュメント・テンプレートが存在する。さらにフォーマット・エディタ39は、現存のテンプレートを編集するかまたは新しいテンプレートを作るかのどちらによっても、ユーザが、新聞をフォーマットするための個人化されたテンプレートを指定できるようにする。とにかく各々のドキュメント・テンプレートは、個人化された新聞のタイトル、インデックス/ヘッディング、副へッディング、テキスト等ついてのページレイアウト情報、フォント情報、スタイル情報、色などを指定する。

【0041】個人用ニュース・プロファイル・エディタ 16、サイト・ドライバー36、プロファイル・マネー ジャ38のためのサンプルのコードが付録3Aに含まれる。第5A図および第5B図は、個人用ニュース・プロファイル・エディタ16の動作をより詳細に説明するフローチャートである。第5A図は、個人用ニュース・プロファイル19のうち、ウエブ・サイトへのアクセスおよびそれらのサイトからのデータ検索に関係する部分を定義するときの、個人用ニュース・プロファイル・エディタ16の動作を説明する。

【0042】第5A図のステップS500において、個 人用ニュース・プロファイル・エディタ16がユーザに よりスタートされる。ステップS501において、エデ ィタはウエブ・リーダ34を起動させる。ユーザの個人 IDがそれからステップS502において検索される。 個人用ニュース・プロファイルがその I. Dに対して既 に存在するなら、ステップS503からステップS50 4に進み、ユーザがフォーマット・エディタへスキップ するという選択を与えられる。そのような個人用ニュー ス・プロファイルが存在しなければ、個人用ニュース・ プロファイル・エディタ16はステップS505の"学 習モード"に入る。一旦学習モードに入ると、個人用ニ ュース・プロファイル・エディタ16はステップS50 6に進み、そこでユーザからのウエブ・コマンド(即 ち、ハイパー・メディア・リンクを横断するというコマ ンド)を入力し、そのコマンドを、サイト・ドライバー 36を使ってウエブ・リーダに転送する。サイト・ドラ イバー36は、ウエブ・リーダ34が訪れてきたウエブ サイトの序列的なログを維持する。ステップ S 5 0 7 で は、個人用ニュース・プロファイル・エディタ16は、 そのウエブ・コマンドから抽出規則を創成する。この規 則により、本ニュース検索システムは、ユーザがウエブ サイトをブラウジング(内部のハイパーリンク上をクリ ックする) する際における選択基準を後で繰り返すこと を可能にする。

【0043】その規則は、少なくとも、ウエブサイトの 横断を繰り返すための構造的な基準を指定する。たとえ ば、ユーザが特定のインデックス/ヘッディングの下に ある記事すべてにアクセスするならば、この規則は、そ のインデックス/ヘッディングの下の全ての記事は検索 されるものであると指定するはずである。本発明のひと つの実施形態では、上記規則は、ユーザから入力され た、内容に基づく(content-based)基準(即ち、キーワードに基づく基準)を含むこともできる。これら内容に 基づく規則は、たとえば、(1)ある単語がひとつの記 事に在るべきことを要求することができる、(2)ある 語を有する記事を除外することができる、(3)単語の ブール組み合わせを要求することができ、(4)キーボードに基づく順位を有し構造上の基準に基づいて選択さ れる記事をランク付けして、それから最高順位を有する 記事の選択を要求することができる、または(5)広告 のようなあるタイプの記事を除外することができる。

【0044】構造的でそして内容に基づくcontent-base d除外規則のためのシンタックスの例が付録2で説明される。異なる型の規則がいくつか示される。ウエブサイトの横断をある数のリンクに限定するだけの規則もある。また他のものは、日付およびキーワードに基づいた除外ルールもある。ひとつの特に順応性のある規則は、記事がキーワード分析に基づいてランク付けされ、最高点の記事が選択されるようにするものである。他のルールは"平坦化"規則を含む。これらの規則は、後に詳細に説明されようが、抽出データ・ツリーの平坦化を制御する。

【0045】少なくとも、この規則は、ユーザの選択 (即ち、第1ページ、第1のドキュメント、全てのリン クなど)、必要なパスワード情報、ブラウザーコマンド などについての構造上の情報を含む。この規則は、ま た、サイト・プロファイル20へのポインタ即ち参照、 並びに、その中の適切な情報を含む。サイト・プロファ イル20を保守するために、一般的な(ユーザが指定し ない)情報がサイト・ドライバー36により使用され る。この方式では、先に論じらアドレス情報と複数のユ ーザに共通のパスワードとが、上述したように、サイト ・プロファイル20において保守することができる。た とえば、サイト・ドライバー36は、コマンドまたは他 のドキュメントへのハイパーリンクを、この規則内のウ エブページに格納するが、ウエブサイトの完全なアドレ スをこの規則に格納することはない。そのアドレス情報 はサイト・プロファイル20に格納される。

【0046】ステップS508では、ウエブ・コマンド 30 から作られた規則を定義する規則データは、第3B図のような抽出(extracted)データ・ツリー27のような抽出データ・ツリーに格納される。このデータ・ツリーは、ウエブから検索されるデータの構成を反映するリンクのリストである。ステップS509では、ユーザが終了して(即ち、ユーザがウエブサイトを終了して)いなければ、フローは、次のウエブ・コマンドを求めてステップS506に戻り、終了していれば、フローはステップS510へ進む。

【0047】この点で、個人用ニュース・プロファイル 40 の創成は、サイト・プロファイル20が格納要求を最小にし、そして一般的なサイト情報を集中化させるために使用されて来た点を除いて、ワード処理プログラムに共通するマクロ命令の創成に大いに類似してなされてきた。格納要求をさらに最小にするために、そしてニュース検索システムの順応性をより高めて効率のよいものにするために、抽出規則はここで編集され、余分のリンクや、同じサイトへの複数のリンクアクセスなどを取り除く。このことはステップS510でなされ、結果としてまとめられた規則は、個人用ニュース・プロファイル1 50

9の最初の部分となる。

【0048】別の形態では、個人用ニュース・プロファイル・エディタ16は、前もって格納された個人用ニュース・プロファイルをユーザが編集できるようにするか、または、たとえばニュースサイトやヘッディング記事だけやキーワードなどを指定することにより、ユーザがドキュメント構成のプレファレンスを指定できるようにするグラフィカル・ユーザ・インタフェースとして呼び出されても良い。どちらの場合においても、その結果は個人用ニュース・プロファイル19であり、ウエブサイトへのポインタの一覧と、1つ又は複数のウエブサイトを横断するための抽出規則からなる。

【0049】上記の説明をよりよく理解するために、個人用ニュース・プロファイルの実施形態およびサイト・プロファイルの実施形態およびサイト・プロファイルの実施形態が付録1に示される。次に、第5B図で説明されるように、制御は進んで、ユーザに、カスタムの新聞用テンプレートを修正するための選択を与える。即ち、ステップS511で、新聞用テンプレートが定義されて、個人用ニュース・プロファイル19に格納さたか否かが決定される。もし新聞用テンプレートが定義されているのならば、ステップS512において、ユーザは、テンプレートを編集するか、またはステップS520へ進行するかの選択を与えられる。ユーザがテンプレートの編集を選択する場合、またはどの新聞用テンプレートの編集を選択する場合、またはどの新聞用テンプレートも定義されていなかった場合には、フローはステップS513へ進む。

【0050】ステップS513では、ユーザは、カスタム・テンプレートを作るか、または予め定義されたテンプレートを使用するかの選択を行う。ユーザが予め定義されたテンプレートを使用したい場合は、ステップS514で、指定した予め定義されたテンプレートを得、ステップS519において、それを個人用ニュース・プロファイルに加える。そうしたくない場合は、フローはステップS515へ進み、そこではフォーマットエディタ39が呼び出される。

【0051】フォーマットエディタ39は、ユーザに数多くのフォーマット用オプションを提供するグラフィック・ユーザ・インターフェースを有する。ステップS516では、フォーマットエディタ39は、どの新聞のセクションを本新聞に印刷すべきか、どのウエブサイトのニュース記事をそれぞれのセクションに置くべきか、それぞれの欄をどのようにレイアウトすべきかの、いずれかまたはどちらもユーザが定義できるようにする。この点で、どのウエブサイトのニュース記事を第1面として使用すべきか、どのウエブサイトのニュース記事をとびネス欄として使用すべきか、どのウエブサイトのニュース記事をスポーツ欄として使用すべきかなどを、ユーザは指定することができる。さらにステップS516で、どのような副へッディングがそれぞれの欄に合うかだけでなく、それぞれのインデックス/ヘッディングをどこ

にリストすべきか、ユーザは定義することができる。

【0052】ステップS517では、フォーマットエディタ39は、ニュース記事の、インデックス/ヘッディング、副ヘッディング、 飯者名を記す行 (バイライン)、および本文のためのフォント形式を、ユーザが定義できるようにする。ステップS518では、フォーマ

ン)、および本文のためのフォント形式を、ユーザが定義できるようにする。ステップS518では、フォーマットエディタ39は、ユーザに、インデックス/ヘッディングの色、タイトルの色などを定義させる。この点では、レイアウトエディタ39は、ユーザに利用できるフォントおよび色の型を、このシステムのプリンタ能力に 10 基づいて決定することができる。

【0053】一旦全ての情報がカスタム・テンプレート のために集められると、ステップS519で、フォーマ ットエディタはその情報を個人用ニュース・プロファイ ル19に加える。変形例では、プロファイルマネージャ -38もまた、このカスタムフォーマットをテンプレー トとして、他のユーザに使用させることができる共通の 領域に格納可能できるようにしてもよい。この場合、そ のカスタム・テンプレートへのポインター若しくは参照 だけを個人用ニュース・プロファイル19に格納する。 【0054】ステップS520では、個人用ニュース・ プロファイル・エディタ16は、自動的な新聞配送の時 間および方法をユーザに設定させる(即ち、印刷する か、後で印刷するためにディスクドライブ 5 に格納す る)。これらの設定は個人用ニュース・プロファイル1 9に加えられる。より具体的にいうと、ユーザのコンピ ュータに電気が提供され続けている場合には、本ウエブ ニュース検索システムは指定された時間に自動的に起動 される。本システムは、個人用ニュース・プロファイル 19にリストされているウエブサイトから記事を検索す 30 ることになる。ニュース記事を検索すると、その記事 は、個人用ニュース・プロファイル19にある新聞テン プレートに基づいてフォーマットされる。フォーマット された個人化された新聞はそれから印刷されるか、後で 見るために格納される。新聞配送の時間が設定されない 場合は、ユーザはいつでもこのウエブニュース検索シス テムを実行することができる。

【0055】個人用ニュース・プロファイル19が一度作られてしまうと、このウエブニュース検索システムは起動されると、ウエブニュース・サイトを横断して、いるいろのニュース記事をウエブニュース・サイトから自動的に検索することによって、個人化された新聞を組み立て、そして個人用ニュース・プロファイル19に示された新聞用テンプレートに基づいて、ニュース記事を印刷することができる。本発明のウエブニュース検索システムがどのようにしてこの機能を実行するかについては次に説明される。

【0056】 (個人用ニュース・プロファイルを用いた ドキュメントの検索) 第6図は、本発明が個人用ニュー ス・プロファイル19に従って、ウエブから記事を検索 50 する方式に関する具体的なブロック線図である。(第6 図は、また、検索された記事が線形のドキュメントの中 に平坦化されてフォーマットされる方式も説明する。こ れらの機能は、この明細書の次の項においてより詳細に 説明される。)

第6図で示されるが、ウエブ・プリンタ17はニュース 記事の検索を引き受ける。ウエブ・プリンタ17は最終 のユーザ用アプリケーションであり、本発明の機能を実 行するために、個人用ニュース・プロファイル19、サ イトプロファイル20、ウエブ・リーダ34、および出 カインターフェース40と連絡する。

【0057】ウエブ・プリンタ17は、どのウエブ・サ イトにアクセスすべきか、これらのサイトからどのデー タを検索すべきかを決定するために、個人用ニュース・ プロファイル19を見る。ウエブ・プリンタ17はま た、一般的なサイト情報を求めてサイト・プロファイル 20も見る。ウエブ・プリンタ17は、種々のウエブ・ サイトにアクセスし、そのサイトからデータを検索する 目的で、個人用ニュース・プロファイル19並びにサイ ト・プロファイル20にある情報に従って、ウエブサー バー35を通じてウエブにコネクトするようにウエブ・ リーダ34に指令する。ウエブ・リーダ34は検索され たデータをウエブ・プリンタ17に送る。ウエブ・プリ ンタ17はそのデータを使用して抽出データ・ツリーを 組み立てる。ウエブ・プリンタ17は、それから、抽出 データ・ツリーを平坦化して線形ドキュメントに変換 し、そして、その線形ドキュメントを出力インターフェ ース40を通じて出力用にフォーマットする(尚、この 明細書の次の項においてより詳細に説明される)。

【0058】第6図で説明されるように、ウエブ・プリンタ17は、ウエブ・リーダ・インターフェース50、サイトドライバー51、ツリー・マネージャー41、およびフォーマッタ42という、4つのプログラム モジュールを含む。ウエブ・リーダ・インターフェース50は、上記のウエブ・リーダ・インターフェース37のように、ウエブ・プリンタ17をウエブ・リーダ34に接続する。

【0059】サイトドライバー51は、サイトプロファイル20および個人用ニュース・プロファイル19にアクセスし、そこに格納されたデータをウエブ・リーダ34はそのデータを使って、いろいろのウエブ・サイトにアクセスし、そこからデータを抽出す。上記のように、この取り出されたデータは、ウエブ・プリンタ37により、抽出データ・ツリーを組み立てるために使用される。

【0060】ツリー・マネージャー41は抽出データ・ツリーを管理する。この点で、ツリー・マネージャー41は取り出されたデータの構成の前記抽出データ・ツリーにおける経路をキープする。これにより、ウエブ・プリンタ17が、同じ記事に二度アクセスすることが防止

され、ウエブサイトを不必要に再訪することが防止され、また、ウエブ上のあるハイパー・メディア・ドキュメントの組織にあるサイクル(ループ)に捕まることを避けることができる。別の形態では、ツリー・マネージャー41は、抽出データ・ツリーと同じ機能性を提供するリンクされたリストを参照して、そのデータをブロック(データ・ツリーの中に直接格納する方式とは反対に)に格納することができる。ツリー・マネージャー41のためのサンプルコードは付録3Bに含まれる。

【0061】フォーマッタ42は、抽出データ・ツリー 10を平坦化して線形ドキュメントにすること、およびその線形ドキュメントを個人化された新聞の形にフォーマットすることを引き受ける。フォーマッタ42は、その印刷基準と、個人ニュース・プロファイル19に示されたフォーマット情報(即ち、新聞テンプレート)に従ってそれらの機能を実行する。フォーマッタ42のためのコードの見本は付録3Bに含まれる。

【0062】より詳細に言うと第7図は、流れ図である。ウエブ・プリンタ17が、ウエブ・リーダ34を使って、どのようにして、個人用ニュース・プロファイル 2019に従ってウエブを横断し、そのプロファイルに従って、どのようにして、望まないデータを除外しながらウエブから記事を取り出すかを説明するフローチャートである。

【0063】ウエブ・プリンタはステップS700から 開始する。ステップS701で、ウエブ・プリンタ17 は、ユーザの指定した個人用ニュース・プロファイル か、または、サイトドライバー51を使用するディスク ドライブ5に格納されたデフォルト個人用ニュース・プ ロファイルのどちらかを検索する。この点で、コンピュ ーター装置1は一人以上のユーザにより使用される可能 性があるために、1個かそれ以上(そのうちの1個はデ フォルトとして指定される)個人用ニュース・プロファ イルが装置に格納されてもよい。その指定された個人用 ニュース・プロファイルを取り出すとすぐに、ウエブ・ プリンタ17は、ステップS702で、なんらかのニュ ースデータが前にディスクドライブ5(即ち、前になさ れた自動ニュース送付によって) に格納されているか、 またはニュース記事が個人用ニュース・プロファイル1 9を使用して検索されるべきかを決定する。

【0064】ニュースデータがディスクドライブ5に存在する場合には、ステップS703で、その格納されたニュースデータが取り出され、フローは、次の項で詳述される第8図のステップS801に進行する。これに対し格納されたニュースデータが何も存在しない場合、ウエブ・プリンタ17はステップS704でウエブ・リーダ34を呼び出す。この動作は、個人用ニュース・プロファイルの定義に関して前に説明されたものと同じウエブ・リーダ34であることに留意されたい。

【0065】呼び出されると、ウエブ・リーダ34は、

ステップS705で、ワールド・ワイド・ウエブのようなネットワークへのコネクションを提供するウエブサーバー35に接続する。それから、ウエブ・プリンタ17は、個人用ニュース・プロファイル19から検索された情報に基づいて、訪ねるべき一番目のウエブサイトのためのアドレスをウエブ・リーダ34に提供する。ステップS706で一度目的のウエブサイトに接続されると、ウエブ・プリンタ17は、次のウエブページへウエブ・ヴリンクをウエブ・リーダ34に提供する。このコマンド/リンクは、個人用ニュース・プロファイル19が検索すべきであると示す情報を含む。ステップS707で、ウエブ・リーダ34はこの情報に従ってウエブを横断する。

【0066】ステップS708で、ウエブ・リーダ34は、個人用ニュース・プロファイル19にある規則に従って目的の情報を取りだし、それをウエブ・プリンタ17に送る。従って、データの除外はこのステップにおいて行われる。個人用ニュース・プロファイル19の規則は、個人化された新聞からデータを除外するための、構造的な内容に基づくcontent-based基準を指定する。この構造的な規則は、ウエブ・リーダ34によりアクセスされたウエブサイトの構造に基づき、その取り出された情報を制限する。前記内容に基づく基準は、それの内容に基づいてその取り出された情報を制限する。個人用ニュース・プロファイルを創成する方法に関してすでに説明されたように、個人用ニュース・プロファイル19の取り出し規則のシンタクスの例は付録2に含まれる。

【0067】規則に基づいた除外に加えて、ステップS 708ではメディアの型式による除外が行われる。即 ち、印刷不可能なメディア型式のデータが抽出データ・ ツリーから除外される。たとえば映画および音響データ が除外できる。ウエブ・プリンタ17は、取り出したデ ータを、ディスクドライブ5(またはメインメモリ1 4) の、ツリーマネージャー41により管理される抽出 データ・ツリーに格納する。別の形態では、上記データ は、すでに説明されたように、リンクされたリストを参 照してブロックに格納することができる。ウエブ・プリ ンタ17は、ステップS709で、ウエブサイトのウエ ブページから全ての情報を完全に取り出すために、ステ ップS707へ戻る。ひとつのウエブサイトを完全に検 索すると、ステップS710で、ウエブ・プリンタ17 はさらに多くのサイトを訪ねるべきかどうかを決定する ために、ツリーマネージャー41を使用して、個人用ニ ュース・プロファイル19に残るサイトを、抽出データ ・ツリーにあるサイト構成情報と比較する。さらに多く のウエブサイトを訪ねる必要がある場合は、ステップS 710からステップS706に戻り、ここでニュース記 事は上記と同じ方式で取り出される。これに対して、個 人用ニュース・プロファイル19に記録されているウエ 50 ブサイトのすべてが訪ねられて、記事がすべて取り出さ

れてしまうと、フローは第8図のステップS801に進む。

【0068】〈取り出しデータの平坦化とフォーマット〉第8図は抽出データ・ツリーがどのように平坦化(flattened)されてフォーマットされるのかを示すフローチャートである。この発明の構成は、ウエブからデータを検索するとき(第6図で説明される)と同じである。実際、平坦化処理およびフォーマット処理は、少なくともある限度までにおいて、データ検索取り出し処理と同時に行うことができる。

【0069】第8図のステップS801で、抽出データ・ツリーは平坦化される。つまりデータの構造が抽出データ・ツリーから線形ドキュメントへ転換されるということである。この行程は個人化された新聞からより多くのデータを除外する機会を提供するもので、たとえば前記データ・ツリーのノードを平坦化されたドキュメントの中へ含めるだけでよい。この除外処理は個人用ニュース・プロファイル19にある平坦化規則により制御される。

【0070】データが線形ドキュメントの形に平坦化さ 20 れた後、そのデータはステップS802で、個人用ニュース・プロファイル19で示されるテンプレートに従ってフォーマットされる。このテンプレートの定義は、予め定義されたテンプレート、またはカスタムのテンプレート、のどちらの場合もすでに論じられている。最後にフォーマットされて完全に個人化された新聞は出力インターフェース40に送られる。このインターフェースは、プリンタ7に接続するプリンタインターフェース10、ディスプレイ2へ接続するディスプレイインターフェース11、またはモデム/ファックス・インターフェ 30 ース6でも可能である。

【0071】 (第2の実施形態) … HTMLフォーマッタ 本発明の第2の実施形態はハイパー・メディア・ドキュ メントを処理するためのシステムである。このシステム はハイパー・メディア・ドキュメントにアクセスし、ハ イパー・メディア・ドキュメントからアドレスを抽出 し、そしてハイパー・メディア・ドキュメントから抽出 されたアドレスをコンテナに格納する。このシステム は、コンテナに格納されたアドレスの番地に格納された データを処理するという処理機能を起動し、コンテナに 40 格納されるアドレスに格納されるデータをメモリにダウ ンロードし、そして予め決定された構成の情報に従っ て、ダウンロードされたデータから予め決定されたデー タを抽出す。その予め決定されたデータはそれから、フ オーマットされたドキュメントを生成するための、予め 定義されたフォーマットセッティングに従って、フォー マットされ、そしてフォーマットされたドキュメントは 処理ファンクションに従って処理される。本発明の第2 の実施形態は、第2図で言及されたHTMLフォーマッ タ18として説明される。

【0072】HTMLフォーマッタ18の例は、本出願人のCanon Information System Incにより製造されたウエブ・フォーマッタである。第2の実施形態はウエブ・フォーマッタに関して説明される。しかしながらHTMLフォーマッタ18はウエブ・フォーマッタの実施形態に限定されないこと、そして以下の説明の精神および範囲の内にある別の様々な実施形態が可能であることに留意されたい。

【0073】ウエブ・フォーマッタは、ネットスケー プ、モザイクおよびインターネット・エクスプローラの ようなウエブ・ブラウザと共に使用できる独立型のユー ティリティ・ソフトウエアである。要するに、ウエブ・ フォーマッタはウエブページからデータを抽出し、その 抽出されたデータから、突発的に発生したデータを除去 し、そしてその除去後のデータをフォーマットされたド キュメントの形に再フォーマットする。フォーマットさ れたドキュメントは印刷されるか、RTF (Rich Text For mat)形式で格納されるか、またはマイクロソフト・ワー ド(MS Word)、ワード・パーフェクト(Wordperfect)、ワ ード・パッド(Wordpad)等の、あらゆるRTFコンパティブ ル・エディタにおいて編集されることができる。ウエブ ・フォーマッタは、Microsoft のWindows (登録商標) のようなウインドウ環境から起動することができる。そ のようなウインドウ環境から、ウエブ・フォーマッタ は、起動ウインドウ内のウエブ・フォーマッタ・アイコ ン(不図示)をダブルクリックし、Windowsのスタート メニューからウエブ・フォーマッタを選択し、所定のウ エブ・ブラウザからURL( uniform resource locator ) アイコン(不図示)をドラッグし、そしてそれをウエブ フォーマッタ・アイコンの中へドロップすることによ り、もしくはウエブ・ブラウザが開始されたときにウエ ブ・フォーマッタを自動的に呼び出すことにより、起動 することができる。

【0074】上記第1の実施形態とは異なって、ウエブ・フォーマッタは、1個または2個以上のウエブのページから特定の型式のドキュメントを創成するための基準を指定するために、予め定義された個人用ニュース・プロファイルを使用することはない。むしろ、第2実施形態のウエブ・フォーマッタは、1個または2個以上のウエブのページから新聞等のような特定の型式のドキュメントを創成するために、ユーザ指定の基準に依拠する。これらの基準はユーザにより、グラフィック・ユーザ・インターフェースを通じて対話式に入力される。

【0075】以下でより詳細に説明されるが、ウエブ・フォーマッタは二つのモード即ち最小機能モードおよびフル機能モードで作業する。最小機能モードでは、ウエブ・フォーマッタのグラフィック・ユーザ・インターフェースは、必ず、画面に表示されるウエブのページと同時に表示されるフローティング・プリント・ボタンでなければならない。この特徴によって、ユーザがウエブを

探索するときに、フローティング・プリント・ボタンを クリックするだけで、ユーザはウエブのページを処理す ること、フォーマットすること、およびプリントアウト することができる。

【0076】ウエブ・フォーマッタのフル機能モードで は、ウエブ・フォーマッタのグラフィック・ユーザ・イ ンターフェースは、ユーザに対して、処理対象のウエブ のページのURLアドレスを入力するためのインターフェ ース・スペースと、当該ドキュメントの個人用のタイト ルを入力するためのインターフェース・スペースと、そ 10 のドキュメント用の形式 (フォーマット) を選択するた めのインターフェース・スペースと、フォーマットされ たドキュメントの第1ページをプレビュー(preview)す るためのインターフェース・スペースと、そして、ドキ ュメントを印刷するか、またはドキュメントを RTFファ イルとしてセーブするか、または RTFエディタを使用し てそのドキュメントを見る/編集するかするためのイン ターフェース・スペースを提供する。まず、フル機能モ ードのためのグラフィック・ユーザ・インターフェース から最初に説明される。なぜなら、ユーザが最小機能モ 20 ードを選択できるのはフル機能モードのインターフェー スからであるからである。

【0077】第9A図はウエブ・フォーマッタのフル機能モードのためのグラフィック・ユーザ・インターフェース43を説明する。このグラフィック・ユーザ・インターフェース43を説明する。このグラフィック・ユーザ・インターフェース43は、ウエブ・フォーマッタの最初の起動後すぐに画面に表示される。あらゆる対話式のウインドウ形式のソフトウエア・アプリケーションの場合と同様に、ユーザはグラフィック・ユーザ・インターフェース43と、マウス4およびキーボード3によって(指示 30し、クリックすることにより)対話する。

【0078】第9A図で示されるように、グラフィック・ユーザ・インターフェース43は、その初めから終わりまでの間で、ユーザがフォーマットすべきドキュメントのURLアドレス、およびそのドキュメントのフォーマットを指定できる、フィールド44および46から49までを含む。フィールド44から始めると、ユーザは、ウエブ・フォーマッタにより処理すべきウエブのページのURLアドレス(e.g.,http://www.cis.canon.com/tis/tishome.htm)を入力する。ユーザがURLアドレスを入力するにはいくつかの方法がある。ユーザは、(1)アドレスをURLフィールド44へ直接にタイプするか、

(2) ウエブ・ブラウザでURLアドレスをコピーして、 そのURLアドレスをURLフィールド44に貼り込むか、

(3) URLアドレスをウエブ・ブラウザから、グラフィック・ユーザ・インターフェース43へ、またはウエブ・フォーマッタのアイコンヘドラッグするか、または(4) カレントURLボタン54をクリックする。

【0079】カレントURLボタン54に関して、ユーザ がカレントURLボタン54をクリックすると、ウエブ・ フォーマッタはアクティブなウエブ・ブラウザを捜し当て、ウエブ・ブラウザに、現在のウエブのページのアドレスに関して訪ねる。次にウエブ・ブラウザは現在のウエブのページのアドレスをウエブ・フォーマッタに対して提供し、ウエブ・フォーマッタはそのアドレスをURLアドレス・フィールド44に置く。URLボタン(Current URL)54が起動され、どのウエブブラウザも目下ランしていない時は、ウエブ・フォーマッタは、第9A図の・ダイアログ・ボックス56を表示する。

【0080】同図に示すように、・ダイアログ・ボックス56は、キャンセル(Cancel)ボタン57およびブラウザ・スタート(Launch Browser)ボタン59を含む。キャンセルボタン57は、URLアドレスをCurrent URLボタン54を介してURLアドレスフィールド44に入力するようにというユーザの要求をキャンセルするものである。これに対してブラウザ・スタート・ボタン59は、ウエブ・フォーマッタで指定されるウエブ・ブラウザを開始する。以下で言及されるが、ウエブ・フォーマッタは、当該ウエブ・フォーマッタと共に使用されるウエブ・ブラウザを含む所定の情報により前もって構成立てられている。ウエブ・フォーマッタの構成は以下でより詳細に説明されよう。

【0081】ウエブ・フォーマッタの別の実施形態では、ファイル名をURLアドレス・フィールド44に入力してもよい。たとえばこれら選択可能な実施形態は、ユーザがハイパー・リンクされたマニュアルを書籍形式のフォーマットにフォーマットしたい時には、ユーザはファイル名をURLアドレスフィールド44に入力する。その後ウエブ・フォーマッタは、指定されたウエブのページを介する時と同様の方式でそのファイルを処理して、そのハイパー・リンクされたマニュアルを望ましいように再フォーマットする。

【0082】グラフィック・ユーザ・インターフェース 43に論を戻すと、タイトル・フィールド(Title) 46 は、ユーザがフォーマットされたドキュメントのため の、個人用タイトルを入力できるようにする。そのタイトルは直接タイプして、タイトルフィールド46に貼り付けることも可能である。フォーマッティング用のフィールド(Styles, Columns, Spacing) 47乃至49は、ウエブ・フォーマッタによって出力されるべきドキュメントのフォーマットを定義する。他のフォーマッティング用フィールドを選択するには、スクロールバー55のような、それぞれのフォーマッティングフィールド選択用のスクロールバーをクリックすることによりアクセスされる。これらのフィールドの各々は以下で詳細に説明される。

【0083】スタイル(Styles)フィールド47は出力ドキュメントをフォーマットするための4個のオプションを提供する。これらのスタイルは、小ヘッディング(headers)、余白(margins)等の大きさの如き、出力ドキュメ

ントの特性に関するものである。スタイル・オプションは、コンテンポラリー(contemporary)、フォーマル(Formal)、ファン(Fun)およびプロフェッショナル(Professional)を含む。もちろん本発明はこの4個のスタイルのオプションに限定されず、必要なら他のスタイルを加えることができる。

【0084】コラム(Column)フィールド48はフォーマットされた出力ドキュメントのコラムの数を定義する。2つのコラムのオプションが利用でき、即ち単一コラム(Single)および多重コラム(Multiple)である。しかしながら本発明はこの2個のオプションに限定されない。単一コラムオプションは、要望があればドキュメントをシングル・コラムの形にフォーマットする。これに対し、多重コラムオプションは、ドキュメントを、予め指定された数のコラムの形にフォーマットする。本発明の好適な実施形態では、マルチプルのオプションは2個のコラムに対して設定される。しかしながらいかなる数でも設定できる。

【0085】スペーシング(Spacing)フィールド49はフォーマットされた出力ドキュメントの行間を定義する。3個のオプションがウエブ・フォーマッタにおいて提供されているが、しかし他のオプションも要望通りに加えることができる。これら3個のオプションは、圧縮(Condensed)、ノーマル(Normal)、および読み易い間隔(Easy-to-read)であって、そのうち圧縮は最小の行間、読み易い間隔は最大の行間である。

【0086】グラフィック・ユーザ・インターフェース43はまたプレビュー(Preview)ボタン60を提供する。プレビュー・ボタン60をクリックすることによって、ユーザはビューイングエリア61で、フォーマット30されたドキュメントの最初のページを試しに見ることができる。試し見のためのフォーマットされたドキュメントの一例が第9A図で示される。

【0087】第9Aおよび9B図で示されるように、ウエブ・フォーマッタはまたオプション(Options)ボタン61を含む。オプション・ボタン61は、フォーマット用オプションをさらにユーザに提供するもので、ウエブ・フォーマッタにより使用されてフォーマットされたドキュメントを創成する。ユーザはオプションボタン61をクリックすることによって、アクティブにすることが40できる。これにより第9B図のオプション・ダイアログ・ボックス62がディスプレー2に現れる。

【0088】第9B図で示されるように、オプション・ダイアログ・ボックス62は、一般(General)オプション64、コンテナ(Container)オプション66、およびストリップ・メタ情報(Strip Meta Info)オプション67を含む。「一般」オプション64は「テキストのみ(Text Only)」というリストボックス72、「ページ内リンクのインデックス(Index of links in the page)」というリストボックス73、および、「浮動画無し(Nofl 50

oating pictures)」というリストボックス74を含む。これらのオプションは、各々のリストボックスにおいてチェックマークなどにより選択されるように指示される。オプションについての説明からも明らかであるが、「一般」オプション64のオプションの2個以上を同時に選択することができる。

【0089】「テキストのみ(Text Only)」リストボッ クス72は、ウエブページにある画像のすべてを取り除 いて、そこにあるテキストだけを印刷するように、ウエ ブ・フォーマッタに命令する。「ページ内リンクのイン デックス(Index of links inthe page)」リストボック ス73は、ウエブ・フォーマッタに命令して、ウエブペ ージに現在ある全てのURLのリストをフォーマットされ たドキュメントの末尾に加えさせる。好適には、URLの リストは上付き文字として印刷され、リストにあるURL の末尾の位置は肉太活字で示される。「浮動画無し(No floating pictures)」リストボックス74は、ウエブ・ フォーマッタに命令して、フォーマットされたドキュメ ントの特定の領域でドキュメントの全ての画像を印刷さ せる。従ってこのオプションが選択されると、画像が特 定の領域にぴったりとはまるように、ウエブ・フォーマ ッタは画像を必要なだけ縮小させる。

【0090】ストリップ・メタ情報(Strip Meta Info) オプション67は、ウエブ・フォーマッタにより処理されるウエブのページから不必要な情報を容易に除去させるエンジニアリング用のオプションである。このオプションは、

- (1) 「無し(None)」:ウエブのページから何も除去しないようにウエブ・フォーマッタに命令する、
- (2) 「第1の水平ルールまで(Till the first horizo ntal rule)」:予め定義された第1および第2の水平のフォーマット規則に至るまで(たとえばページを横断する水平の線に至るまで)、全てのリンクと画像を取り除くように、ウエブ・フォーマッタに命令する、
- (3) 「第1のテキストまで(Till the first tex t)」:ウエブのページで最初のおよび最後のテキストが発生するまで、リンクおよび画像をすべて取り除くように、ウエブ・フォーマッタに命令する。

【0091】ストリップ・メタ情報(Strip Meta Info)オプション67は一度に1つだけ選択することができる。第9B図で示されるように、そこでの選択は、そのオプションに隣接する小さな丸内に点を付すことによって指示される。コンテナ(container)オプション66は、第9B図に示されているように、ドキュメントと、そのドキュメントのコンテナ76に格納アドレスを処理するためのオプションを提供する。コンテナオプション66の説明に先立ち、コンテナ76が説明される。

【0092】コンテナ76は選択されたドキュメントの URLアドレスを格納する。フィールド44に入力される ドキュメントのアドレスはコンテナ76に追加される。

ということを示すために使われる。この点で、2個以上

URLがコンテナ 7.6 に入力される順序は、URLのデータがウエブ・フォーマッタにより処理される順序を意味する。第9 B図で示されるように、コンテナ 7.6 は一度フルになると、それのアイコンは番号 7.7 により示されるアイコンに変化する。

【0093】ユーザがコンテナ76のアイコンをクリックすると、メニュー77が画面に表示される。メニュー77は5個のオプション、即ち、「開く(Open)」79、「空にする(empty)」80、「プリントする(Print)」81、「編集する(Edit)」82および「記憶する(Save)」84を提供する。これらのオプションはアクティブにされると、ハイライトが点くが、詳細は以下で説明される。

【0094】「開く(Open)」 79はアクティブにされると、第9B図のコンテナ・コンテント(Container Contents)スクリーン87を画面に表示する。コンテナ・コンテント(Container Contents)スクリーン87は、4個のボタン、即ち、現在のURLをコンテナ76に加える「URL追加(Add Current URL)」ボタン88と、ユーザがコンテナ76にあるURLをハイライトさせて除去できるようにする「デリート(Delete)」ボタン89と、ユーザがコンテナ76を空にできるようにする空(Empty)ボタン90、およびユーザがコンテナコンテント・スクリーン87を閉じることができるようにする終了(Done)ボタン91を提供する。忘れてならないのは、ユーザはまた、メニュー77の「空にする(empty)」80をクリックすることにより、コンテナ76の内容を空にすることもできるということである。

【0095】さらにコンテナ76に格納されたURLの順序を、異なるURL同士をドラッグしドロップすることに 30より、変更することもできる。先に言及したが、URLはコンテナ76に現れる順序に従って処理されるため、上述の特徴により、ユーザはコンテナ76にあるURLの処理順序をそれぞれ変更することができる。プリント(Print)ボタン81、編集(Edit)ボタン82およびセーブ(Save)ボタン84は、アクティブされた時、コンテナ76に格納されるURLにより定義されるウエブのページで全てのデータを、ウエブ・フォーマッタにダウンロードさせ、それらのデータをユーザの指定通りにフォーマットさせ、フォーマットされたウエブのページを格納するR40TFファイルを創成させ、そしてセーブするか、編集するか、またはRTFファイルを印刷するかの選択されたアクションを行わせる。この処理は以下でより詳細に説明される。

【0096】オプション・ダイアログ・ボックス62に 論を戻すと、コンテナオプション66は、「内容をテー ブル印刷(Print table of contents)」リストボックス 92と「処理後に空にする(Empty after processing)」 リストボックス94を含む。説明のように、リストボッ クスのチェックマークは、リストボックスが選択された のリストボックスが一度に選択されることができる。 「内容をテーブル印刷(Print table of contents)」リストボックス92が選択されると、コンテナ76にある全てのURLのタイトルをフォーマットされた出力ドキュメントの内容リストとして印刷するように、ウエブ・フォーマッタに命令する。「処理後に空にする(Empty aft

オーマックに命令する。「処理後に空にする(Empty aft er processing)」リストボックス94がアクティブになると、ウエブ・フォーマッタに命令して、印刷か、編集か、またはドキュメントのセーブが済んだ後に、ユーザがそうするのを待たずとも、自動的にコンテナ76を空にさせる。

【0097】コンテナオプション62の一部分として、「RTFエディタの選択(Select RTF Editor)」ボタン69、キャンセル(Cancel)ボタン70、およびオーケー(0K)ボタン71もまた設けられている。「RTFエディタの選択(Select RTF Editor)」ボタン69をクリックすることによって、ユーザはRTFファイル・エディタ(その例は上述した)を選択することができる。この選択は、たとえば、所定のRTFエディタ(不図示)を一覧表示するもうひとつの・ダイアログ・ボックスを表示し、そしてそのRTFエディタのうちの1個を選択することによって、なされる。キャンセルボタン70はコンテナオプション62をキャンセルし、オーケーボタン71はコンテナオプション62で選択されたオプションを確認し、それからその・ダイアログ・ボックスを閉じる。

【0098】第9A図で示されているが、グラフィック・ユーザ・インターフェース43は、また「印刷(Print)」アイコン96、「編集(Edit)」アイコン97、「セーブ(Save)」アイコン99、「ヘルプ(Help)」ボタン100、「終了(Done)」ボタン101、および「最小化(Minimizing)」アイコン102を含む。ユーザはマウスを使用してそれらをクリックすることにより、それらの動作のどれでも選択することができる。

【0099】「印刷(Print)」アイコン96は、ウエブ・フォーマッタによりフォーマットされるウエブのページのコピーを、ユーザが何枚でも印刷できるようにするプリント・ダイアログ・ボックス(不図示)を開く。

「編集(Edit)」アイコン97は、フォーマットされたウエブのページを格納する RTFファイルを開き、それを予め決められたRTFエディタによって編集可能にする。

「セーブ(Save)」アイコン99は、ユーザがフォーマットされたウエブのページに名前を付け、RTFファイルとしてセーブできるようにするセーブ・ダイアログ・ボックス(不図示)を開く。「ヘルプ(Help)」ボタン100は、作業しているウエブ・フォーマッタのためのヘルプメッセージを提供し、そして「終了(Done)」ボタン101はウエブ・フォーマッタからイグジットする。「最小化(Minimizing)」アイコン102は、以下でさらに詳しく説明される上述のウエブ・フォーマッタの最小化モー

ドをアクティブにする。

【0100】第90図は、ウエブ・フォーマッタの作業 の間に、それにより提供されるメニューを図示する。こ れらのメニューは、ファイル(File)メニュー103、エ ディット(Edit)メニュー104、およびウインドウ(Win dow)メニュー106を含む。ファイルメニュー103の 機能は、セーブ(Save)アイコン99、編集(Edit)アイコ ン97および印刷(Print)アイコン96の機能にそれぞ れ一致するころの、セーブ、編集、および印刷のオプシ ョンを提供する。イグジット(Exit)オプションもまたフ ァイルメニュー103から抜け出るために提供される。 最後にファイル(File)メニュー103は「HTMLファイル を開く(Open HTML File)」オプション107を提供す る。このオプションは、ローカルHTMLファイル、即 ちネットスケープ(NetScape)からセーブされたファイル などのユーザのコンピューターに存在するハイパー・メ ディアファイルを開くか、またはURLをウインドウズの デスクトップヘドラッグ/ドロップすることによって創 成されるURLファイルを開く能力を、ユーザに提供す る。「HTMLフィルを開く(Open HTML file)」オプション 107はまた、他のウエブファイル処理製品により創成 されるファイルを、ウエブ・フォーマッタを使用して、 RTFファイルとしてフォーマットおよび印刷すること、 セーブおよび編集、またはそのどちらかをすることがで きるように、それらのファイルを開くために必要な手段 も提供する。

【0101】エディット(Edit)」メニュー104は「UR Lのペースト(Paste URL)」オプション109を提供す る。この「URLのペースト(Paste URL)」オプション10 9は、ウエブのページからコピーされたURLアドレス等 のペーストバッファの内容を、上記URLフィールド44 へペーストするものである。 ウインドウメニュー106 は、ウエブ・フォーマッタの使用法、維持管理、背景に 関する情報をユーザに提供する「ヘルプ(Help Topic s)」オプションと、ウエブ・フォーマッタの版番号およ びコピーライト表示を容れる・ダイアログ・ボックス (不図示) をユーザに提供する「ウエブフォーマッタに ついて(About WebFormatter)」オプションとを提供す る。ウインドウ(Window)メニュー106はまた「プレフ ァレンス(Preferences)」オプション110も含む。こ の「プレファレンス(Preferences)」110は、第9D 図で示されるプレファレンス・ダイアログ・ボックス1 12を開く。

【0102】プレファレンス・ダイアログ・ボックス1 12は、ウエブ・フォーマッタを構成化しあるいは再構 成化するために使用される。第9D図で示されるが、プ レファレンス・ダイアログ・ボックス112は、「ミニ マイズ・ビュー(Minimize View)」オプション113、 「一般(General)」オプション114、および「使用WWW ブラウザ(WWW Browser to use)」オプション115を含 50 む。「ミニマイズ・ビュー(Minimize View)」オプショ ン113は、ウエブ・フォーマッタのグラフィック・ユ ーザ・インターフェースを最小モードで配列するように 設定させることができる。2組のオプションが提供され ている。第1の組は「印刷(Print)」、「編集(Edit)」 および「セーブ(Save)」とを含む。これらのオプション は、第9B図のプリント(Print)アイコン96、エディ ット(Edit)アイコン97、およびセーブ(Save)アイコン 99に対応する。これらのオプションのひとつに接する リストボックスに、チェックマークが現れると、そのオ プションのためのアイコンが、たとえばプリントアイコ ン、エディットアイコン、および、またはセーブアイコ ン等の最小化モードで画面に表示される。二つ以上のオ プションを同時に選択することができる。これに関し て、第9E図は、最小化モードにあるウエブ・フォーマ ッタのための、グラフィック・ユーザ・インターフェー スの典型例116を示す。

【0103】第9D図に戻ると、「ミニマイズ・ビュー (Minimize View)」オプション113は、また、「行(Row)」と「スタック(Stack)」のオプションも含む。これらのオプションは、最小化モードに在るウエブ・フォーマッタにおいて、「行(Row)」を選択して水平に、または「スタック(Stack)」を選択して垂直に表示するように設定するというグラフィック・ユーザ・インターフェースを提供できる。これらのオプションのひとつだけは同時に選択することができる。前記の例として、グラフィック・ユーザ・インターフェース116は、一列のアイコンに対応する。

【0104】「使用WWWブラウザ(WWW Browser to us e)」オプション115は、ウエブ・フォーマッタと共に、どのWWWブラウザを使用するべきかを決定する。説明のように、Netscape、InternetExplorerおよびMosaicはブラウザ・オプションとして好適に提供されているが、しかしながら他のブラウザ・オプションもまた提供できる。要求があれば、これらのオプションのうち1個だけは同時に選択されることもできる。デフォールトのブラウザー・オプションはNetscape Navigatorである。

【0105】「一般(General)」オプション114は、「ブラウザと共にスタート(Auto-startwithbrowser)」オプション117、「最小視でオープン(Open in minimized view)」オプション118、「\_ページ以上の印刷の前に警告(Warn before printing more than \_\_ pages)」オプション119、および、「\_MBs以上の印刷の前に警告(Warn before saving more than MBs)」オプション120とを含む。「ブラウザと共にスタート(Auto-startwithbrowser)」オプション117は、ウエブ・ブラウザが、アクティブのときに、ウエブ・フォーマッタが自動的に呼び出されるようにする。このオプションが選択されない(それがデフォルトである)場合は、ウ

20

インドウ環境でウエブ・フォーマッタのアイコンにダブ ルクリックすることによって、ウインドウズ起動メニュ ーからウエブ・フォーマッタを選択することによって、 またはURLをウエブ・ブラウザから、上で詳述されるウ エブ・フォーマッタのアイコンヘドラッグおよびドロッ プすることによって、ウエブ・フォーマッタは開かれ る。「最小視でオープン(Open in minimized view)」オ プション118が選択されると、最小化モードでウエブ ・フォーマッタを開く。しかしながらデフォルトはフル 機能モードである。「\_ページ以上の印刷の前に警告(w 10 arn before printing more than \_ pages)」」オプシ ョン119および「MBs以上の印刷の前に警告 (Warn be fore saving more than MBs)」オプション120は、 フォーマットされたドキュメントのセーブされるページ の数、およびそれらのページによりそれぞれ使用される メモリスペースの量を、ユーザが制御できるようにす る。これらの両方のオプションのためのデフォルトは、 与えられるべき警告が出ないというものである。一般(G eneral)オプションの2個以上が同時に選択されること ができるのは言うまでもない。

【0106】プレファレンス・ダイアログ・ボックス1 12はまた、ユーザが選択したプレファレンスを取り消 すキャンセル(Cancel)ボタン121および、ユーザが選 択したプレファレンスを確認するオーケー(OK)ボタン1 22を含む。上の説明のように、ウエブ・フォーマッタ は、プレファレンス・ダイアログ・ボックス112を通 じて、最小化モードに直接入力するように構成される か、さもなければユーザが第9B図のミニマイジングア イコン102を通じて最小化モードに入力することがで きる。また上で言及したが、第9日図は最小化モードに 30 あるウエブ・フォーマッタのためのグラフィック・ユー ザ・インターフェース116の一例を示す。このグラフ イック・ユーザ・インターフェース116は、ユーザが ウエブを探索している間に、浮動(floating)インターフ ェースとして表示される。従ってユーザがウエブのペー ジを見るときに、ユーザはまたグラフィック・ユーザ・ インターフェース116を見ることになる。グラフィッ ク・ユーザ・インターフェース116(グラフィック・ ユーザ・インターフェース43で示されたアイコンに構 造的にも機能的にも一致するアイコンを第9日図で含 む)の適切なアイコンをクリックすることによって、ユ ーザは現在のウエブのページをとらえて、処理し、その ウエブのページをRTFファイルの形でフォーマットし、 そしてそのRTFファイルをセーブし、編集およびまたは プリントすることができる。別の方法では、ユーザはウ エブ・ブラウザからURLをドラッグし、それをアイコン のひとつにドロップすることができる。

【0107】ユーザは、適当なマウスボタンをダブルク リックすることによって、最小化モードにあるウエブ・ フォーマッタを再配列することができる。この実行によ

り、プレファレンス・ダイアログ・ボックス112に一 致するようなプレファレンス・ダイアログ・ボックスが ディスプレー2に現れる。従って、そのユーザはウエブ ・フォーマッタの構成を希望通りに変更することができ る。もしユーザが、最小化モードからフル機能モードに 入力したい場合には、ユーザは、第9E図の最大化(Max. imizing)アイコン117をクリックする必要があるだけ である。

【0108】第10図はウエブ・フォーマッタの作業を 説明するフローチャートである。ウエブ・フォーマッタ はステップS1000で起動される。上記のように、起 動はウインドウ環境で、ウエブ・フォーマッタにダブル クリックすることによって行うことができる。ウエブ・ フォーマッタがどのように構成化されたのか、即ちフル 機能モードであるのか、さもなければ最小化モードであ るのかに応じて、グラフィック・ユーザ・インターフェ ース43に類似のグラフィック・ユーザ・インターフェ ースか、またはグラフィック・ユーザ・インターフェー ス116に類似のグラフィック・ユーザ・インターフェ ースかのどちらかがステップS1000で表示される。 以下では、ウエブ・フォーマッタのデフォールトモード はフル機能モードであるために、グラフィック・ユーザ ・インターフェース43のそれと同類のグラフィック・ ユーザ・インターフェースがステップS1000で表示 されることとする。

【0109】次にステップS1001で、ウエブ・フォ ーマッタは、上記プレファレンス・ダイアログ・ボック ス112、およびオプション・ダイアログ・ボックス6 2を通して構成化される。ユーザが、以前に設定された ウエブ・フォーマッタについての上記構成を変更したく なければ、この行程は必要ではない。ステップS100 2で、ドキュメント・フォーマット・データは、上記フ ィールド44と46~49に入力される。より具体的に 言うと、ユーザは、URL(またはファイル名)をURLフィ ールド44へ入力する。以下に説明されるが、 ・フォーマッタは、この情報を使用してそのURLに格納 されたウエブのページを処理し、ウエブ・フォーマッタ の前記構成ならびにフィールド46~49に入力された データに基づいてRTFファイルを創成する。

【0110】ステップS1003で、前述のウエブ・リ ーダ34に類似のウエブ・リーダが実行される。このウ エブ・リーダはステップS1004で、ワールド・ワイ ド・ウエブ等のネットワークに接続する。次にステップ S1005で、URLまたはファイル名が入力されたかど うかが決定される。上述のように、ウエブ・フォーマッ タの好適な実施形態では、URLだけを入力することもで きる。しかしながら、ウエブ・フォーマッタの別の実施 形態はファイル名のエントリーを可能にするので、URL アドレスにあるファイルとは別のファイルを処理する方 法についての説明がなされることになる。

【0111】URLがフィールド44に既に入力されてい る場合は、処理はステップS1006へ進む。ステップ S1006ではウエブ・リーダは、URLアドレスにより 指定されるハイパー・メディア・ドキュメント(たとえ ばホームページ) にアクセスする。ステップS1007 では、ウエブ・フォーマッタはウエブ・リーダに、ハイ パー・メディア・ドキュメントを横断するよう命令す る。従ってウエブ・フォーマッタはウエブからURLアド レスを選択し、そのアドレスをコンテナ76に格納す る。必要なアドレスのすべてが一旦は選択され、プリン ト等の処理機能が起動されると、ウエブ・フォーマッタ は、コンテナ76のアドレスに格納されるデータを、メ モリ5にダウンロードする。ウエブ・フォーマッタは、 それから、オプショナル・ダイアログ・ボックス62で 設定される構成情報に基づいて、そのダウンロードされ たデータから、予め決定されたデータを抽出し、その抽 出されたデータをメモリ5に格納する。このようにして たとえば、オプションウインドウ62にある「テキスト のみ(textonly)」オプション72が行われているなら、 ダウンロードされたデータからテキストだけが抽出され 20 る。処理はそれからステップS1011へ進む。

【0112】これとは異なって、ステップS1005で、HTMLソースファイルのためのファイル名が入力されるなら、ウエブ・フォーマッタはウエブ・リーダに、ファイルの第1のサイトにアクセスするように命令する。ステップS1008およびS1009で、そのサイトが横断されて、データが抽出され、上述のステップS1007と同じ方法で格納される。それからステップS1010で、ウエブ・フォーマッタは、さらに多くのサイトがHTMLソースファイルにリストされるているかどうかを30決定する。そのファイルにさらに多くのサイトがリストされている場合には、フローはステップS1008に戻り、次のサイトがアクセスされる。サイトがそれ以上ない場合には、処理はステップS1011に進む。

【0113】ステップS1011で、ウエブ・フォーマッタは、前に設定されたフォーマット情報に従って、その抽出されたデータを処理する。たとえばコラム・フィールド48が多重(multiple)に設定されている場合は、その抽出されたデータは、多重コラムを有するドキュメントの形にフォーマットされることになる。この処理は、プリント(Print)アイコン96、エディット(Edit)アイコン97、またはセーブ(Save)アイコン99のうちの1つを起動することにより始められ、そして、この処理は、第1の実施形態における処理と同様のものであって、たとえば、そのドキュメントを平坦化し、フォーマット情報に基づいてそのドキュメントをフォーマットするものである。従って、簡潔にするためその詳細な説明は省略される。

【0114】コンテナ内にURLが格納されているドキュ メントが一度ダウンロードされ、予めセットされたフォ ーマットおよび構成に従ってフォーマットされ、ステップS1011でRTFファイルに変換されると、そのRTFファイルはステップS1012で出力される。別の方式では、グラフィック・ユーザ・インターフェースのどのアイコンが起動されていたかに依って、そのRTFファイルは編集されるか、さもなければセーブされるようにしてもよい。

【0115】本発明は図示による特定の実施形態に関して説明されたものである。本発明が、上記実施形態およびその修正に限定されるものではないこと、並びにこの明細書の精神および範囲の内にある限り、種々の変更および修正が可能であることが理解されよう。

## <u>付録 1</u>

ユーザプロファイルのサンプル

このユーザ・プロファイルはwindows.iniのファイル形式で作成されている。

[Defaults]

Count=4

Title=MyDailyPaper

[1

Heading=NewsInBrief

Site=1

Section=FrontPage

MaxLevels=5

Maxpages=10

MaxKBytes=2000

Date=today

Print=level0

Template=1

[2]

Heading=SportsInBrief

Site=2

Section=Sports

MaxLevels=0

MaxPages=10

MaxKbytes=200

KeywordFilter="Football"AND"49ers"

Date=today

Print=level0

0 Template=1

[3]

Heading=MoneyMatters

Site=1

Section=Business

MaxLevels=1

MaxPages=100

MaxKBytes=20000

KeywordFilter = "Computer" OR" hardware" OR" Software"

Date=today

Print=all

Template=2

[4]

Heading=SriLanka

Site=3

Section=HotNews MaxLevels=1 MaxPages=100 MaxKBytes=20000 Date=today

Print=leaves Template=2

サイト・プロファイルのサンプル

#Legend:

#%W-dayoftheweek #%s-sectionpartofURL

[Defaults]
Count=3
[1]

Title=SanJoseMercuryNews

Username=mwickram Password=cannon

StartData=StartHeadlines EndData=EndHeadlines

HomePage=http://www.sjmercury.com/

SectionURL=http://www.sjmercury.com/%S.htm

SectionCount=9
Section1=FrontPage
Section2=International
Section3=National
Section4=Local&State

 ${\tt Section 5=Editorials Commentary}$ 

Section6=Business Section7=Sports Section8=Living

Section9=Entertainment

[1.Sections]
FrontPage=front
International=intl
National=natl
Local&State=loc

Editorials&Commentary=edit

Business=biz Sports=spts Living=liv

entertainment=ent

[2]

Title=TheSanFranciscoChronicle

HomePage=http://www.sfgate.com/chronicle/

SectionURL="http:www.sfgate.com/cig-bin/chronicle/

article-list.cgi?%/S:/chronicle/today"

SectionCount=5

Section1=News

Section2=Business

Section3=Sports

Section4=Editorial

Section5=Datebook

12.Sections1

News=News:MN

Business=Business:BU

0 Sports=sports:SP

Editorial=Editorial:ED

Datebook=Datebook:DD

[3]

Title=TheDayNews

Homepage=

http://www.landa.net/lakehouse/anclWeb/dailynew/

42

SectionURL="http://www.lanka.net/lakehouse/anclWeb

/dailynew/%W/WS.html"

SectionCount=12

20 Section1=Business

Section2=Editorial

Section3=Features

Section4=Foreign

Section5=Letters

Section6=InBrief

Section7=NotNews

Section8=Probes

Section9=Military

Section10=Politics

Section11=Obituaries

Section12=Sports

[3.Sections]

Business=business/intro

Editorial=editorial/final

Features=features/intro

Foreign=foreign/intro

Letters=letters/final

InBrief=inbrief/intro

HotNews=hotnews/intro

Probes=proves/intro

Military=military/intro

Politics=politics/intro

Obituaries=obiturai/intro

Sports=sports/intro

付録2

検索、抽出、印刷のための基準についての文法

サーチのための最大レベル: MaxLevels=<#>

-1:全てのレベルを検索する

0-n: n レベルまで検索する

50 ドキュメントの最大ページ:MaxPages=<#>

n:nページを超えない最後のドキュメント ドキュメントの最大サイズ:MaxKBytes=<#> n:nキロバイトを超えない最後のドキュメント 除外ルール:

Date=today lessthan<#>

today: 今日掲示された記事のみを検索する

lessthan<#>;n:n日以上経過していない記事のみを検索する

Retrieve=all|nosubdir|nothisdir|thissiteonly all:他のサイトからのページを取り出すことを許す nosubdir:サブディレクトリへのURLを除外 nothisdir:このディレクトリへのURLを除外 thissiteonly:このサイトからだけのページを取ってく

キーワードサーチ:

KeywordFilter=<keyword>(AND|OR|NOT)<keyword>: そのキーワードの組み合わせを含むページのみを累積する

## KeywordRank=<#>;n :

ファジー論理を用いてKeywordFilter内のキーワードの 組み合わせに従ってページをランク付けし、上位 n 個の ページを保持する

### KeywordAuthor=<author>:

このauthorにより著作されたページのみを累積する

ExcludeType=ads|nonEnglish

ads:広告を除外する

nonEnglish: 英語でない記事を除外する 平坦化ルール: Print=all|leaves|level=<#>

all: その線形ドキュメント内のツリーにある全てのノードを含める

leaves:その線形ドキュメント内のツリーにある全ての 葉を含める

level=<#>;n: その線形ドキュメント内のツリーn番目のレベルまでを含める

フォーマット化ルール:Template=<#>

n:デフォルトもしくはユーザテンプレート番号nに従って印刷

## 付録3

記述モジュール

### 付録3A

〈個人用ニュース・プロファイル・エディタ・モジュール〉このプロファイル・エディタはユーザ・プロファイルへのアクセスを統御し、CProfileMgrクラスによって表される。また、ユーザ・プロファイルのローディング及びセーブをも統御する。プロファイル・エディタにより提供されるサービスは:

## BOOLNewProfile(CStringfileName);

- そのfilenameにより与えられる新規プロファイルを創成する

BOOLOpenProfile();

- デフォルトのプロファイルをオープンする

44

BOOLOpenProfile(CStringfileName);

- 当該名前のプロファイルをオープンする

CProfileEntry\*GetFirstEntry();

- 次のプロファイルのエントリをロードして返す

CProfileEntry\*GetNextEntry();

- 次のプロファイルのエントリをロードして返す

BOOLWriteEntry(CProfileEntry&entry);

- 当該プロファイル内の新規エントリをセーブする

各々のプロファイルエントリはCProfileEntryクラスにより表された抽出仕様と出力仕様とを含む。その方法は・

CURLGetSiteId();

- そのプロファイル・エントリに含まれるサイトIDを返す

CExtractionSpecGetExtractionSpec();

- そのプロファイル・エントリに含まれる抽出仕様を返す。抽出仕様は、サーチ用のキーワード、レベルに対する限界、ページ、サイズ(キロバイト)を含む

- そのプロファイル・エントリに含まれる出力仕様を返す。出力仕様はフォーマット化命令、ツリー横断ルールを含む

〈ウエブ・リーダ・モジュール〉CWebPageのクラスは、インターネットブラウザへのインタフェースを定義し、実際のウエブのページを表す。また、ウエブページを取って来、そのウエブページ内の他のURLへのリンクや参照を抽出し、ウエブページの内容を維持することになる役目を有する。その方法は:

30 BOOLLoad();

40

- URL、ユーザ名、パスワードを用いてウエブページを 取ってくる

BOOLParse();

- ウエブページ内のデータを解析して、リンクのリスト を作成し、相対URLから絶対のURLに変換する

CURLList\*GetLinks();

- 当該ウエブページ内のリンク・リストを返す

CPageData\*GetData();

- 当該ウエブページに含まれる実際のテキストデータを 返す

voidFilterContent();

- サイトのデータに従ってタイトル及び他の情報を抽出 する

CStringGetTitle();

- サイトのデータに従ってタイトル及び他の情報を返す CStringGetAuthor();

- 当該ウエブページの作者を返す

intGetSize();

- そのデータのサイズをキロバイトで返す

50 CNetworkクラスはOLE機能を内包させ、インターネット

ブラウザとの通信を提供する。

CStringGetUsername();

- 現在セットされているユーザ名を決定する

voidSetUsername(LPCTSTR);

- そのCNetworkオブジェクト内に現在のユーザ名をセットする

CStringGetPassword();

- 現在セットされているパスワードを決定する

voidSetPassword(LPCTSTR);

- そのCNetworkオブジェクト内に現在のパスワードをセ 10 ットする

voidClose();

- 全てのアクチブな接続を切り、そのCNetworkオブジェクトをリセットする

shortRead(BSTR\*pBuffer,shortiAmount);

- 当該ブラウザにより検索されたデータを読み出す longGetStatus();
- 現在のロードの状態を照会する

BOOLOpen(LPCTSTRpURL, shortiMethod, LPCTSTRpPostData, longIPostDataSice, LPCTSTRpPostHeaders);

h le hitter em em le list de marile le s

- ネットワークからURLの取り出しを開始する

CStringGetErrorMessage();

- 発呼者に内部生成のエラーメッセージを提供する shortGetServerStatus();
- サーバにより報知されたエラー状態を決定する longGetContentType();
- 現在のロードの内容の長さ(全バイト量)を返す . CStringGetContentEncoding();
- 現在のロードのMIME符号化方法を返す

CStringGetExpires();

- このロードにより検索されたデータが最早有効でない 時を返す

CStringResolve(LPCTSTRpBase,LPCTSTRpRelative);

- 絶対値URL(十分に調べられた)を生成する BOOLIsFinished();

- ロードが完了したか否かを決定する

shortBytesReady();

- 発呼者に読み出されるべきバイト数を通知する 〈サイト・ドライバ・モジュール〉サイト・ドライバ・ モジュールは、ウエブ・リーダにサイト情報を提供する ことになる。サイト・ドライバは機能的にはプロファイ ル・エディタに類似しており、CSiteDriverクラスによ り表される。提供されるサービスは::

BOOLNewProfile(CStringfileName);

- 当該filenameを与えられた新規プロファイルを創成する

BOOLOpenProfile();

- デフォルト・プロファイルをオープンする

BOOLOPenProfile(CStringfileName);

- 当該名前のプロファイルをオープンする

CSiteProfile\*GetFirstSite();

- 当該最初のサイトのエントリをロードして返す

46

CSiteProfile\*GetNextSite():

- 次のサイトのエントリをロードして返す

BOOLWriteEntry(CSiteProfile&entry);

- 当該プロファイルの新規エントリをセーブする

intNumberOfSites();当該プロファイルに指定されたサイトの数を返す

サイト・プロファイル内のエントリは、そのサイトの基礎URLに関する情報、ニュースソースのタイトル、そのサイトへのアクセス方法に関する情報、セクションデータなどの種々の情報を含み、CSiteEntryクラスにより表される。提供される方法は:

CStringGetURL();

- 当該サイトの基礎URLを返す

CStringGetUsername();

- 当該サイトを求めているユーザ名を返す

CStringGetPassword();

- 当該サイトへのパスワードを返す

- 当該サイトへのタイトルを返す

CStringGetTitle();

- ニュースソースのタイトルを返す

intSectionCount();

- セクションのカウント数を返す

<u>付録3B</u>

〈ツリー・マネージャ・モジュール〉ツリー・マネージャは、本プログラムにおける中心的なデータ構造(ウエブページノードのツリーである)を保守するもので、CP

ageTreeによって表される。CPageTreeはWWWを横断して、前記抽出仕様に従って必要なウエブページを検索し、上記ツリーを構築する。提供される方法は:

CPageTreeNode\*GetRoot();

- 当該ツリーのルートノードを返す

BOOLBuild(CURLURL,CExtractionSpec&spec);

- 個人ニュース・プロファイル抽出仕様に従って本ツリーを構築する

ページツリー内の個々のノードはCPageTreeNodeによって表される。提供される方法は:

40 BOOLAddChild(CWebPage\*page);

- 子供ノードとウエブページのデータとを加える

CWebPage\*GetPage();

- そのノードに含まれるウエブページを返す

intNumberOfChildren();

- そのノードに属する子供の数を返す

BOOLIsLeaf():

- もし葉ノードなら、即ち、子供無しならば、真を返す ウエブのページツリーを横断するには、CTreeIterator クラスが異なる横断方法で定義される。提供される方法

50 は:

#### voidReset();

- 現在の転送をキャンセルし、状態データをリセットする

#### CPageTreeNode\*GetNextNode();

- 深さ方向における最初のサーチでのツリー内の次のノードを返す

#### CPageTreeNode\*GetNextSibling();

- 幅方向における最初のサーチでのツリー内の次のノードを返す

## CPageTreeNode\*GetNextLeaf();

- 深さ方向における最初のサーチでのツリー内の次の葉 を返す

〈フォーマッタ・モジュール〉このモジュールへの入力 は、前記ツリーマネージャにより創成されたウエブペー ジ・ツリー、並びに、ユーザプロファイルに含まれる出 力仕様である。このフォーマッタは、出力仕様のルール に従ってこのツリーを横断し、最終ドキュメントは、出 力仕様内のフォーマット化命令や、ウエブページに含ま れるヘッディング、パラグラフやリストなどのフォーマ ットを用いて定式化される。出力ドキュメントはリッチ 20 ・テキスト・フォーマット(RTF)であり、多くのアプリ ケーションによりアクセス可能である。RTFはテキスト に対して進んだフォーマット言語であり、ドキュメン ト、セクションやパラグラフのフォーマットや、スタイ ルシート、ヘッダやフッタに、ユニコードに対するサポ ートを提供する。GIFフォーマットであるウエブ画像に ついてはサポートはない。サードパーティのライブラリ が、GIFからDIBフォーマットへの変換を行うのに買う か、開発することが必要となろう。本プロトタイプは出 力としてHTMLファイルを生成する。本フォーマッタ 30 はCFormatterクラスで表され、提供される方法は:

# BOOLOpen HTMLFile (CStringfile Name);

- 出力用に名付けられたHTMLファイルをオープンする

## voidCloseHTMLFile();

- そのHTMLファイルをクローズしてセーブする

## BOOLPrintHTML(CPageTree&root, COutputSpec&format);

- 当該ルートと出力仕様が与えられると、そのツリーを 横断し、当該ウエブページの内容をHTMLフォーマットで 印刷する

# BOOLOpenRTFFile(CStringfileName);

- 出力用に当該名前のRTFファイルをオープンする voidCloseRTFFile():
- 当該RTFファイルをクローズしセーブする

## BOOLPrintRTF(CPageTree&root,COutputSpec&format);

- 当該ルートと出力仕様が与えられると、そのツリーを 横断し、当該ウエブページの内容をRTFフォーマットで 印刷する

## BOOLPrint(CPageTree&root,COutputSpec&format);

- 当該ルートと出力仕様が与えられると、そのツリーを

横断し、当該ウエブページの内容をデフォルト・プリン タに印刷する

48

## 【図面の簡単な説明】

【図1】 本発明に従った個人用ニュース検索システム の外観の斜視図である。

【図2】 図1で説明される個人用ニュース検索システムのブロック図である。

【図3A】 本発明に従って情報の変換が行われる際のウエブの構成を示す図。

【図3B】 図3Aに示されたウエブから抽出された抽出データ・ツリーの構成を示す図。

【図3C】 図3Bのツリーから平坦化処理されたドキュメントの構成を示す図。

【図3D】 図3Cの平坦化ドキュメントからフォーマットされたドキュメントを示す図。

【図4】 ウエブを通じてニュース記事を検索するための個人用ニュース・プロファイルが、本発明に従って作られ、あるいは編集される方式を具体的に表すブロック線図で。

20 【図5A】 個人用ニュース・プロファイルがどのように作られ、あるいは編集されるかを説明するフローチャート。

【図5B】 個人用ニュース・プロファイルがどのように作られ、あるいは編集されるかを説明するフローチャート。

【図6】 本発明に従って、ニュース記事がウエブから 検索され、個人用ニュース・プロファイルと関連しなが らフォーマットされる方式の具象的なブロック線図であ る。

30 【図7】 ニュース記事がどのようにして、個人用ニュース・プロファイルと関連して(プロファイルに照合して)ウエブから検索されるのかを説明するフローチャート。

【図8】 検索されたニュース記事がどのようにして、個人用ニュース・プロファイルと関連してフォーマットされ、プリント装置インターフェースに送られるのかを示すフローチャートである。

【図9A】 本発明の第2の実施形態と共に使用される グラフィック・ユーザ・インターフェースを描く図。

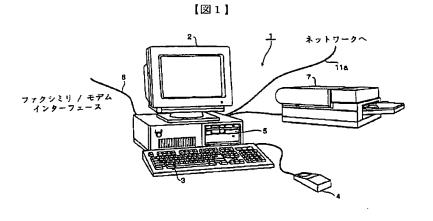
【図9B】 本発明の第2の実施形態と共に使用される グラフィック・ユーザ・インターフェースを描く図。

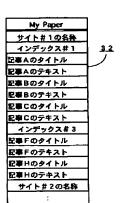
【図9C】 本発明の第2の実施形態と共に使用される グラフィック・ユーザ・インターフェースを描く図。

【図9D】 本発明の第2の実施形態と共に使用される グラフィック・ユーザ・インターフェースを描く図。

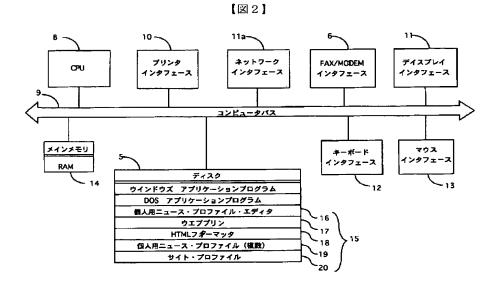
【図9E】 本発明の第2の実施形態と共に使用される グラフィック・ユーザ・インターフェースを描く図。

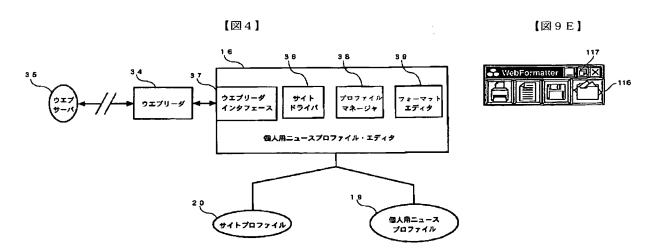
【図10】 本発明の第2の実施形態を説明するフローチャートである。

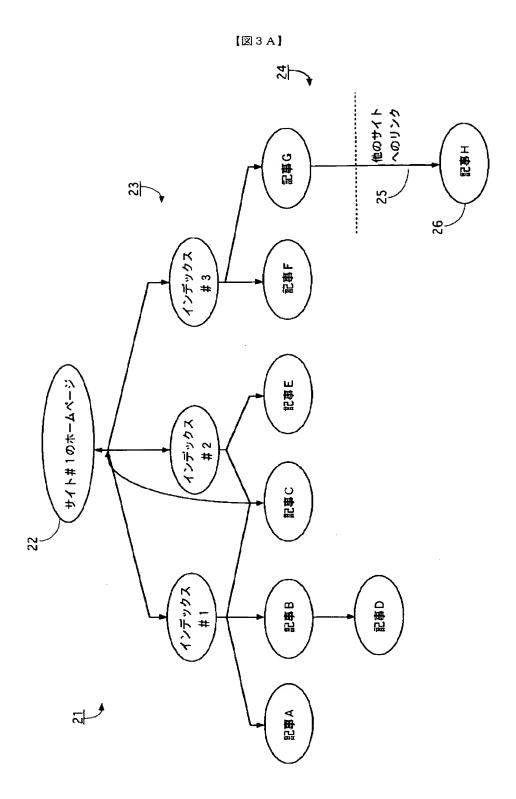


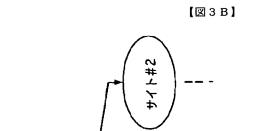


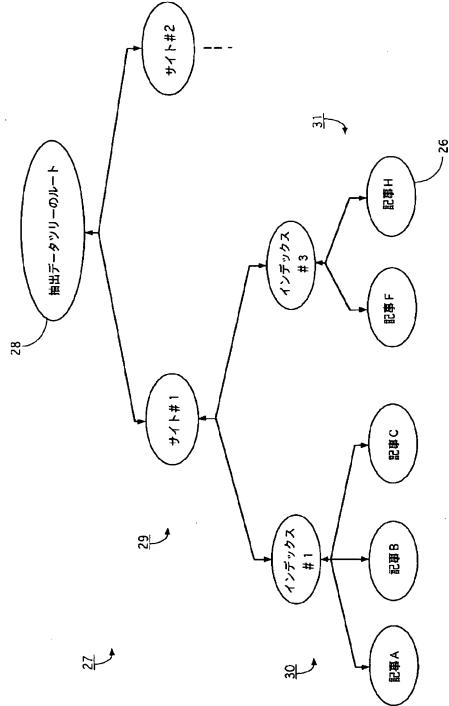
【図3C】

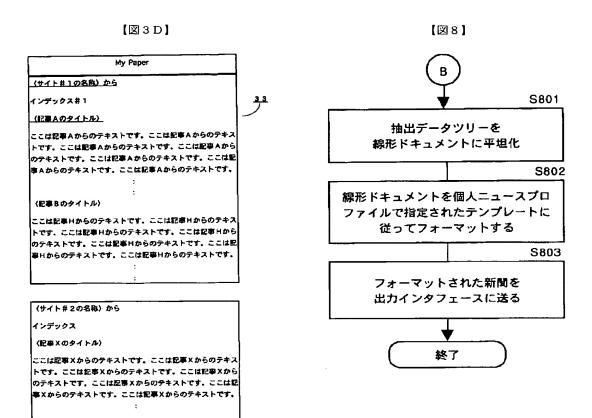


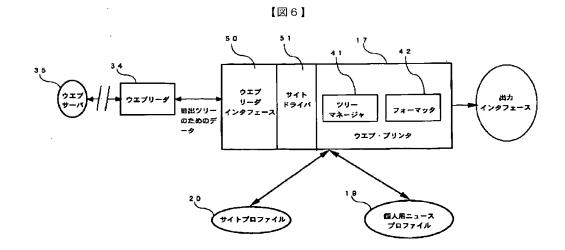




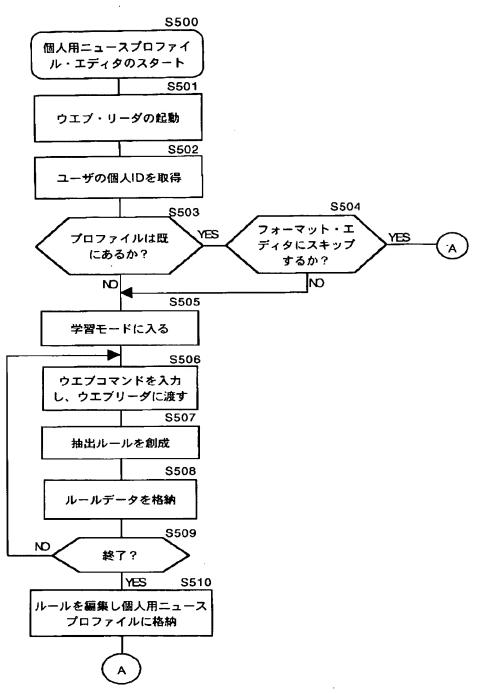




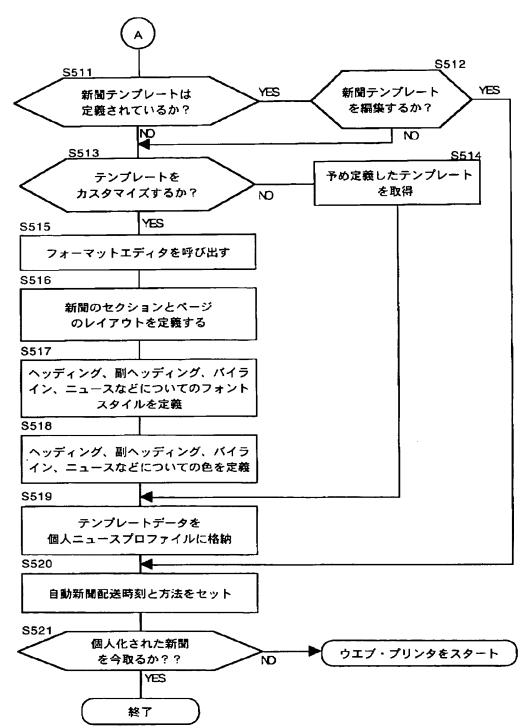


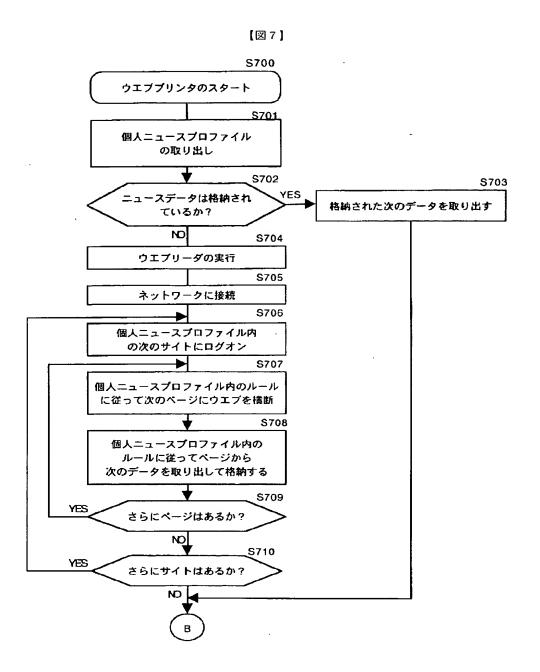


【図5A】

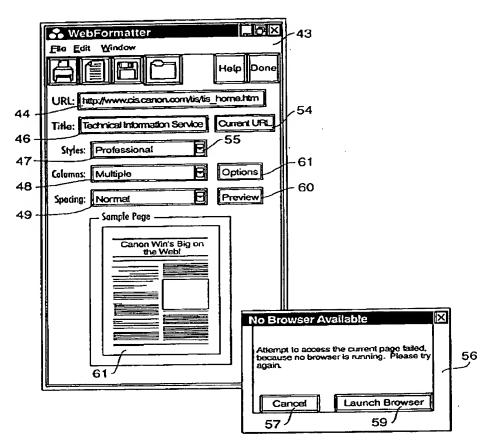


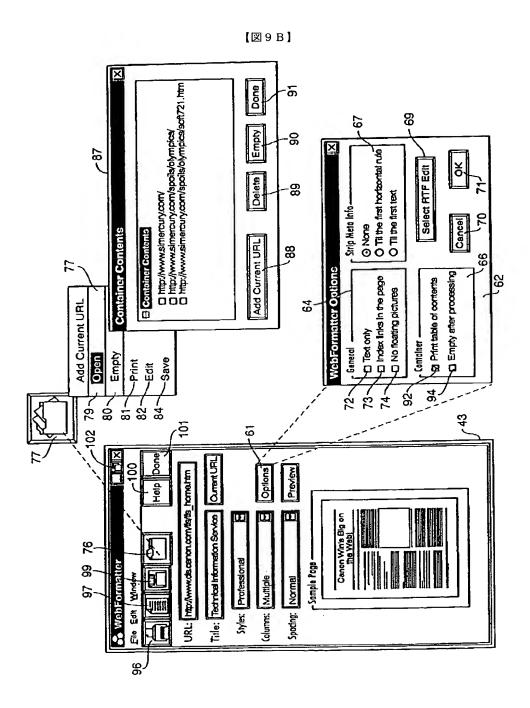
# 【図5B】



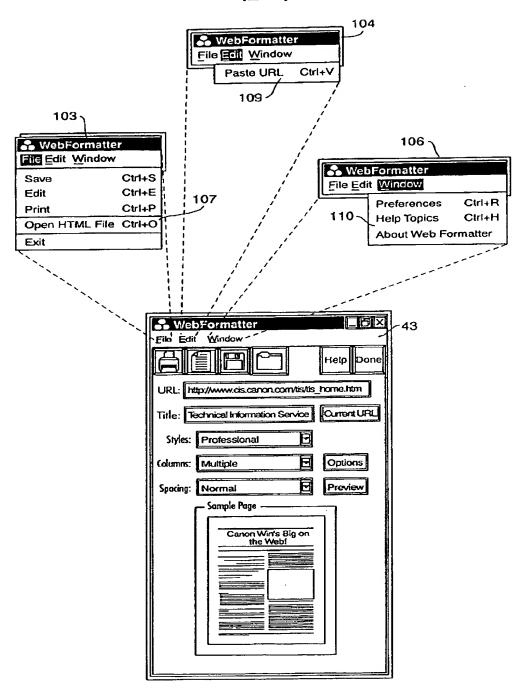


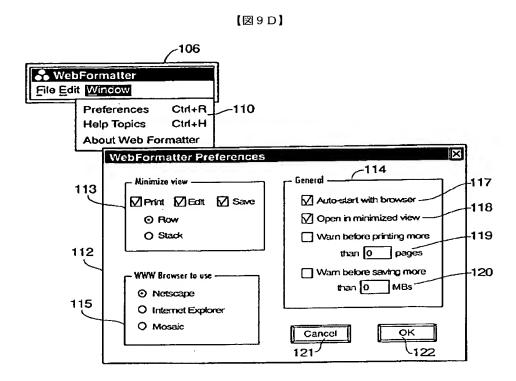
# 【図9A】

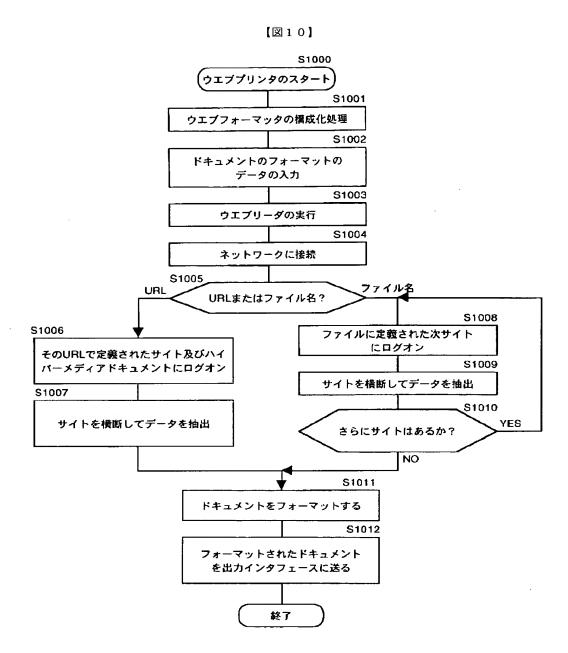




【図9C】







#### フロントページの続き

- (72)発明者 マンジュラ ジー・ ウイックラマラネ アメリカ合衆国 カリフォルニア州 94536, フリーモント, サニースロー プ ドライブ 333
- (72)発明者 パウル エル・ クラーク アメリカ合衆国 カリフォルニア州 94040, マウンテン ビュー, デル メディオコート #208, 2700

#### 【外国語明細書】

- 1. TITLE OF INVENTION
- WORLD WIDE WEB YEWS RETRIEVAL SYSTEM

#### 2. CLAIMS

1. A method for formatting data from at least one hyperme dia document, comprising the steps of:

an accessing step to access the at least one hypermedia do cument;

- a retrieving step to retrieve data from the hypermedia document into an extracted data tree, wherein the data is retrieved based on a structure of the hypermedia document;
- a flattening step to flatten the extracted data tree into a linear document; and
- a formatting step to format the linear document into a for matted document.
- 2. The method of Claim 1, further comprising the step of printing the formatted document.
- 3. The method of Claim 1, wherein said hypermedia document is located on the World Wide Web.
- 4. The method of Claim 1, wherein said hypermedia documen t is located on the Internet.
- $\label{eq:total_state} 5. \quad \text{The method of Claim 1, wherein said hypermedia documen} \\ \text{$t$ is located on an intranet.}$
- 6. The method of Claim 1, wherein said accessing step, said retrieving step, said flattening step, and said formatting step are performed in accordance with a personal-news-profile.
- 7. A method of creating a personal-news-profile for retrieving data from a hypermedia-linked computer network, comprising the steps of:

(2)

accessing the hypermedia-linked computer network; entering a learning mode;

 $\label{traversing} \mbox{ traversing sites on the hypermedia-linked computer network } \\ \mbox{ with commands:} \\$ 

cxtracting at least one rule from the commands; and compiling the at least one rule into the personal-news-pro file.

- 8. The method of Claim 7, wherein the at least one rule s pecifies structural characteristics of sites for traversing the hypermed ia-linked computer network.
- 9. The method of Claim 8, wherein the at least one rule also specifies content-based criteria for traversing the hyperm edia-linked computer network.
- 10. A personalization system for creating a personalizati on profile for a Web site retrieval data retrieval system, the personali zation system comprising:

an input device for inputting data and commands to access the World Wide Web;

a connection to the World Wide Web;

a momory for storing a Web reader, the Web reader for accessing the World Wide Web via the connection to the World Wide Web according to commands from the personalization system; and

a processor for launching the personalization system in response to a user command, wherein the personalization system, upon being launched, (1) launches the Web reader. (2) accesses the Norld Wide Web via the Web reader. (3) enters a learning mode, (4) sends commands to the Web reader to traverse the World Wide Web according to user commands, (5) extracts at least one rule from the user commands, (6) compiles the at least one rule into a personalization profile, and (7) stores the per

(3)

sonalization profile.

11. A method for retrieving articles from a hypermedia-linked computer network and for formatting the articles into a personalized newspaper, the method comprising the steps of:

retrieving a stored personal-news-profile which comprises address data for a site on the hypermedia-linked computer network, command data for accessing data from the site, and newspaper layout commands;

contacting the site based on address data stored in the personal-news-profile;

downloading articles from the site based on command data s tored in the personal-news-profile;

flattening the articles into a linear document; and formatting the linear document into the personalized newspaper according to layout commands stored in the personal-news-profile.

- 12. The method of Claim 11, further comprising the step of printing the personalized newspaper.
- 13. The method of Claim 11, wherein said hypermedia-linke d computer network is the World Wide Web.
- 14. The method of Claim 11, wherein said hypermedia-linke d computer network is on the Internet.
- 15. The method of Claim 11, wherein said hypermedia-linke d computer network is on an intranet.
- 16. The method of Claim 11, wherein the command data for accessing data includes data for selecting articles based on a structure of the site.
- 17. The method of Claim 16, wherein the command data for accessing data also includes data for selecting articles based on a cont ent of the articles.
  - 18. A World Wide Web site data retrieval system for acces

(4)

sing at least one Web site, for retrieving data from the Web site, and f or formatting the data into a personalized document, the system comprisi ng:

an input device for inputting data and commands to access the World Wide Web:

a memory for storing a Web site data retrieval driver which includes a Neb reader, stored Web site address information, stored Web site commands, and stored format information, wherein the memory also includes process steps to connect to a Web site and to issue commands within the connected Web site;

a connection to the World Wide Web; and

- a processor for launching the Web site data retrieval driver in response to a user inputting a command to access the World Wide Web, wherein the Web site retrieval driver, upon being launched, (1) launches the Web reader to connect to the World Wide Web via said connection, (2) retrieves the Web site address information and Web site commands, (3) instructs the Web reader to access the Web site based on the Web site address information and Web site commands, (4) downloads Web site data from the Web site based on the Web site commands, wherein the data is do wnloaded with reference to a linked list so as to avoid hypermedia-links that form loops and so as to avoid repetitious downloading of data that has already been downloaded, (5) stores the Web site data in a linear document, (6) repeats steps 1 through 5 until all addresses in the stored Web site address information have been accessed, and (7) formats the 1i near document into the personalized document based on the format information.
- 19. The Web site data retrieval system of Claim 18, where in the Web site address information, the Web site commands, and the form at information stored in the memory form a personalized-news-profile.

- (5)
- 20. The Web site data retrieval system of Claim 18. furth er comprising a printer for printing the personalized document.
- 21. The Web site data retrieval system of Claim 18, where in the personalized document represents a personalized newspaper.
- 22. The Web site data retrieval system of Claim 18, where in the personalized document represents a personalized magazine.
- 23. The Web site data retrieval system of Claim 18, where in the personalized document represents a personalized book.
- 24. Computer executable process steps stored on a compute r-readable medium, said steps for accessing World Wide Web sites for ret rieving data at the sites and for formatting the data into a personalize d document, said steps comprising:
  - a connecting step to connect to the World Wide Web;
- a retrieving step to retrieve user-defined Web site addres s information, user-defined Web site commands, and user-defined formatti ng commands;
- an activating step to activate a Web reader so as to acces s a Web site based on the user-defined Web site address information and retrieving data from within the Web site based on the user-defined Web s ite commands;
- a downloading step to download the retrieved Web site data from the accessed Web site into an extracted data tree;
- a flattening step to flatten the extracted data tree into a linear document;
- a step to repeat the downloading step and the flattening s top until all addresses in the user-defined Web site address information have been accessed; and
- a formatting step to format the stored data into the personalized document based on the user-defined formatting commands.

- (6)
- 25. The computer executable process steps of Claim 24, further comprising a spooling step to spool the personalized document to a noutput device.
- 26. The computer executable process steps of Claim 25, wh erein the output device is a printer.
- 27. The computer executable process steps of Claim 25, wh erein the output device is a display.
- 28. The computer executable process steps of Claim 24, wh erein the user-defined Web site commands include commands for selecting data based on a structure of the Web site.
- 29. The computer executable process steps of Claim 28, wherein the user-defined Web site commands also include commands for selecting data based on a content of the Web site.
- 30. An apparatus for retrieving news articles from on-lin c news services on the World Wide Web and formatting the news articles i nto a personalized newspaper, the apparatus comprising:

first storage means for storing (1) a personal-news-profil e which comprises addresses data and command data for accessing data from a Web site, and (2) newspaper format commands;

retrieval means for retrieving the stored personal-news-pr of ile and accessing data stored therein;

activating means for activating a Web reader to contact a Web site based on address data stored in the personal-news-profile;

downloading means for downloading news articles from the contacted Web site based on command data stored in the personal-news-profile;

second storage means for storing the downloaded news articles; and

formatting means for formatting the stored news articles i

(7)

nto the personalized newspaper based on the newspaper format commands st ored in the personal-news-profile.

- 31. The apparatus of Claim 30, further comprising spooling means for spooling the personalized newspaper to a printer.
- 32. A method for formatting data from a hypermedia docume nt into a personalized document, comprising the steps of:
- a location specifying step to specify a location of the hy permedia document;
- a type specifying step to specify the type of the hypermed ia document:
- a scope specifying step to specify the scope of data to re trieve from the hypermedia document, wherein the scope is based on a str ucture of the hypermedia document;
- a format specifying step to specify a format for formatting the data retrieved from the hypermedia document into the personalized document:
- an accessing step to access the hypermedia document found at the location specified in the location specifying step;
- a retrieving step to retrieve data from the hypermedia doc ument accessed in the accessing step, wherein the data is retrieved in a ecordance with the type specified in the type specifying step and in acc ordance with the scope specified in the scope specifying step; and
- a formatting step to format the data retrieved in the retrieving step into the personalized document, wherein the data is formatted in accordance with the format specified in the format specifying step.
- 33. The method of Claim 32, further comprising a printing step to print the personalized document.
- 34. The method of Claim 32, wherein the location specified in the location specifying step is a filename.

- 35. The method of Claim 32, wherein the location specified in the location specifying step is a uniform resource locator for the World Wide Web.
- 36. A method of processing a hypermedia document, comprising the steps of:

accessing the hypermedia document;

extracting addresses from the hypermedia document;

storing the addresses extracted from the hypermedia docume nt in a container in a memory;

activating a processing function to process data stored at the addresses stored in the container;

downloading the data stored at the addresses in the container into the memory;

extracting predetermined data from downloaded data in accordance with predetermined configuration information;

formatting the predetermined data in accordance with prede fined formatting settings to generate a formatted document; and

processing the formatted document in accordance with the  $\ensuremath{\text{p}}$  rocessing function.

- 37. A method according to Claim 36, further comprising a step of previewing the formatted document prior to processing the formatted document.
- 38. A method according to Claim 37, further comprising th e steps of:

changing the formatting settings after previewing the document and before processing the formatted document in accordance with the processing function;

re-activating the processing function; and re-formatting the data in accordance with changed formatti

(9)

ng settings to generate the formatted document.

39. A method according to Claim 36, wherein the addresses are stored in the container in the order that the addresses are input into the container; and

wherein the processing function processes the predetermine d data in the order that the addresses are stored in the container.

- 40. A method according to Claim 39, further comprising the step of rearranging the addresses stored in the container by dragging and dropping the addresses within the container.
- 41. A method according to Claim 36, further comprising a step of inputting the formatting settings and configuration information via a graphical user interface.
- 42. A method according to Claim 41, wherein the graphical user interface comprises plural processing icons, one of which activate s the processing function.
- 43. A method according to Claim 42, wherein the graphical user interface is displayed in plural modes.
- 44. A method according to Claim 43, wherein the plural mo des comprise (1) a fully-functional mode in which the graphical user int erface displays formatting fields, processing options, menus and the processing icons, and (2) a minimizing mode in which the graphical user interface displays only the processing icons.
- 45. A method according to Claim 44, wherein the graphical user interface displayed in the minimizing mode is displayed during browsing the hypermedia document.
- $46. \;$  An apparatus for processing a hypermedia document, comprising:
  - a Web read which accesses the hypermedia document; means for extracting addresses from the hypermedia documen

(10)

t:

a memory including a container which stores the addresses extracted from the hypermedia document;

a graphica) user interface having processing icons which a ctivate at least one processing function to process data stored at the a ddresses stored in the container; and

processing means which (1) downloads the data stored at the addresses stored in the container into the memory, (2) extracts product ermined data from downloaded data in accordance with predefined configuration settings, (3) formats the predetermined data in accordance with predefined formatting settings to generate a formatted document, and (4) processes the formatted document in accordance with the processing function.

- 47. An apparatus according to Claim 46. further comprising previewing means for previewing the formatted document prior to processing the formatted document.
- 48. An apparatus according to Claim 46, wherein the addresses are stored in the container in the order that the addresses are input into the container; and

wherein the processing function processes the predetermine d data in the order that the addresses are stored in the container.

- 49. An apparatus according to Claim 48, further comprising dragging and dropping means for dragging and dropping the addresses listed in the container in order to rearrange the addresses in the container.
- 50. An apparatus according to Claim 46, further comprising inputting means for inputting the formatting settings and configuration information via a graphical user interface.
  - 51. An apparatus according to Claim 50, wherein the graph

(11)

ical user interface comprises plural processing icons, one of which activates to the processing function.

- 52. An apparatus according to Claim 51, further comprising display means for displaying the graphical user interface in plural modes.
- 53. An apparatus according to Claim 52, wherein the plura I modes comprise (1) a fully-functional mode in which the graphical user interface displays formatting fields, processing options, menus and the processing icons, and (2) a minimizing mode in which the graphical user interface displays only the processing icons.
- 54. An apparatus according to Claim 53, wherein the graph ical user interface displayed in the minimizing mode is displayed during browsing the hypermedia document.

#### 3. DETAILED DESCRIPTION OF INVENTION

#### Field Of The Invention

The invention relates to a data retrieval system which aut omatically traverses hypermedia documents on a computer network and auto matically retrieves information from those documents based on a match be tween the structure of the documents and a personalized data retrieval s tructure. More particularly, the invention can retrieve articles from a news service, from a magazine service, or from a combination of both se rvices which are located on the World Wide Web, a private computer network that supports hypermedia links, or any other hypermedia—linked computer system.

For example, there exists a Web site for retrieving news a rticles from the New York Times and a Web site for retrieving articles from People magazine. The retrieval system of the invention can traverse through such Web sites and select articles based on a personalized data retrieval structure. The personalized data retrieval structure may inc

(12)

lude commands to retrieve a full text of the front page only, headlines of the business section, headlines of the stock section and sports section, etc. In addition, the personalized data retrieval structure may include content-based rules to retrieve articles with certain keywords, to exclude articles with certain keywords, or to include articles based on a rule-based content analysis. The invention also provides a method for synthesizing all retrieved news articles and printing the synthesized news articles into a newspaper-type format in which each of the articles is arranged based on a user's predefined layout.

While the above example is in the context of the Web, hypermedia documents can reside on other types of networks besides the Web, such as an intranet. An intranet is a private computer network that is not connected to outside computer networks. For example, a company's own computer network could be an intranet with hypermedia documents on it. For brevity, the following discussion is made with respect to the World Wide Web. However, it should be understood that the invention applies equally well to any type of computer network that contains hypermedia documents, such as an intranet, different hypermedia—linked computer networks that reside on the Internet other than the Web, etc.

A hypermedia document on the Web can span multiple Web sit es. Such documents can be newspapers, news articles, magazines, catalog s. manuals, memoranda, and the like. For brevity, the following discussion is made with respect to sources of news information. However, it should be understood that the invention applies equally well to any other type of hypermedia document.

#### Description Of The Related Art

The World Wide Web is an on-line source of hypermedia docu ments containing hypermedia text and images that act as links to other d ocuments, Web sites, etc. As a result, documents on the Web are not org anized sequentially. Rather, a user is automatically linked to other do cuments or Web sites to complete the viewing of a document by selecting a hypermedia link, such as a text link or an image link, within the document. Accordingly, an entire document cannot be viewed by scrolling through text.

One popular use of the Web is on-line publication and dist ribution of magazines and newspapers. Currently, many Web news services, such as the New York Times, allow the user to define keywords of inter est and to receive news information, daily or hourly, that contains text matching the keywords. The news information can then be delivered to the user's computer via modem or E-mail. However, most Web news site new spapers, like the New York Times, include too much information, most of which has no interest to the user since the information is retrieved based only on a keyword match.

Other sources of news information are provided through information suppliers like "Individual Inc." Individual Inc. supplies user s with a brief summary of the top twenty most relevant articles based on a user's predefined keywords. This subscription news service allows the cuser to specify five to ten areas of interest based on keywords, which are then prioritized by the user. The information service searches the Web for magazines and newspapers which contain any of the keywords. Based on the keyword searches, twenty of the most relevant articles are selected, compiled into a brief one-page summary, and transmitted to the user via facsimile for the user's review. However, in order to review an entire document rather than the summary, the user must log onto a specific Web site containing the document in order to retrieve and review the document.

There are yet other services which permit the user to personalize a newspaper to be displayed at the user's terminal by storing li

(14)

nks to various news articles from various news sources on the Web. For example, CRAYON "Create Your Own Newspaper" permits a user to select spe cific sections from among links to over twenty-five different on-line newspapers, and to compose the selections into a personalized newspaper. Using CRAYON, it is possible to compose a personalized newspaper containing, for example, links to the international section of the New York Times, the business section of the Wall Street Journal, and the sports section of the Chicago Tribune. The HTML (hypertext markup language) source file for this newspaper is then stored to mass media storage for later use,

While the forgoing news and information services provide convenient ways to keep updated on the news, they do not allow a user to access and view the news in the way that people naturally read a real-would newspaper. Namely, people naturally read a newspaper by scanning the pages of sections that they find interesting and then reading those articles that grab their attention. In other words, people use a structural approach to decide what pages to look at initially (e.g., the first page of the Business and World sections, and the comics page of the Arts section). They then scan the selected pages for articles.

In sum, conventional news and information services do not allow a user to access data from a hypermedia document on the basis of the structure of the document, and then to format that data in a manner that allows the user to scan and read the data in a natural fashion.

#### SUMMARY OF THE INVENTION.

The invention addresses the above deficiencies in the art by accessing at least one hypermedia document, retrieving data from the hypermedia document into an extracted data tree, with the data retrieved based on a structure of the hypermedia document, flattening the extract ed data tree into a linear document, and formatting the linear document

(15)

into a formatted document.

In another aspect, the invention creates a personal-news-p rufile for retrieving data from a hypermedia-linked computer network. The hypermedia-linked computer network is accessed, a learning mode is started, the hypermedia-linked computer network is traversed with commands, at least one rule is extracted from the commands, and the rule(s) is compiled into the personal-news-profile.

In yet another aspect, the invention creates a personaliza tion profile for a Web site retrieval data retrieval system. Data and commands are input to access the World Wide Web and a connection is made to the World Wide Web. A Neb reader is launched, and the Web reader accesses the Web via the connection. In response to user commands, a learning mode is entered into. Commands are sent to traverse the World Nide Web, and at least one rule is extracted from the commands. The rule(s) is compiled into a personalization profile, which is stored.

In yet another aspect, the invention retrieves articles from a hypermedia-linked computer network and formats the articles into a personalized newspaper. A stored personal-news-profile is retrieved. The personal-news profile includes address data for a site on the hypermedia-linked computer network, command data for accessing data from the site, and newspaper layout commands. The site is accessed based on address data stored in the personal-news-profile, and articles at the site are downloaded based on command data stored in the personal-news-profile. The downloaded articles are flattened into a linear document, and the linear document is formatted into the personal-news-profile, newspaper layout commands stored in the personal-news-profile.

In yet another aspect, the invention retrieves data from a World Wide Web site and formats the data into a personalized document.

A Web site data retrieval driver which includes a Web reader, stored W

eb site address information, stored Web site commands, and stored format information is accessed. The invention (1) launches the Web reader to connect to the World Wide Web via a connection to the Web, (2) retrieves the Web site address information and Web site commands, (3) instructs the Web reader to access the Web site based on the Web site address information and Web site commands, (4) downloads Neb site data from the Web site based on the Web site commands, wherein the data is downloaded with reference to a linked list so as to avoid hypermedia—links that form loops and so as to avoid repetitious downloading of data that has already been downloaded. (5) stores the Web site data in a linear document. (6) repeats steps 2 through 5 until all addresses in the stored Web site address information have been accessed, and (7) formats the linear document into the personalized document based on the format information.

In yet another aspect, the invention accesses and retrieve s data at World Wide Web sites and formats the data into a personalized document. The invention connects to the World Wide Web, retrieves user defined Web site address information, user defined Web site commands, and user defined formatting commands, and activates a Web reader so as to access a Neb site based on the user defined Neb site address information. The Web reader is used to download data from the Web based on the user defined Neb site commands, and the data is downloaded into an extracted data tree. The downloading continues until all addresses in the user defined Neb site address information have been accessed. The extracted data tree is flattened into a linear document, and the flattened document is formatted into the personalized document based on the user defined formatting commands.

In yet another aspect, the invention retrieves news articles from on-line news services on the World Wide Web and formats the news articles into a personalized newspaper. The invention stores a persona

(17)

l-news-profile which comprises addresses data and command data for acces sing data from a Web site and newspaper format commands, retrieves the stored personal-news-profile and accesses the data stored therein, activates a Web reader to contact a Web site based on address data stored in the personal-news-profile, downloads news articles at the contacted Web site based on command data stored in the personal-news-profile, stores the downloaded news articles, and formats the stored news articles into the personal-news-profile.

In yet another aspect, the invention formats a hypermedia document into a personalized document. A location of the hypermedia document is specified, a scope of data to be retrieved from the hypermedia document is specified, wherein the scope is based on a structure of the hypermedia document, and a format is specified for formatting the data retrieved from the hypermedia document into the personalized document. The hypermedia document found at the specified location is accessed, data is retrieved from the hypermedia document in accordance with the specified hypermedia document type and in accordance with the specified scope, and the data is formatted into the personalized document in accordance with the specified format.

In yet another aspect, the invention is a system for proce ssing a hypermedia document. The system accesses the hypermedia document, extracts addresses from the hypermedia document, and stores the addresses extracted from the hypermedia document in a container. The system activates a processing function to process data stored at the addresses stored in the container, downloads the data stored at the addresses stored in the container into a memory, and extracts predetermined data from downloaded data in accordance with predetermined configuration informati

(18)

on. The predetermined data is then formatted in accordance with predefined formatting settings to generate a formatted document, and the formatted document is processed in accordance with the processing function.

In preferred embodiments, the system inputs the formatting settings and configuration information via a graphical user interface.

The graphical user interface comprises plural processing icons, one of which activates the processing function. By virtue of the graphical user interface, a user can interactively set a document's format and change that format should a change be desired.

In particularly preferred embodiments, the graphical user interface is displayed in plural modes. The plural modes comprise (1) a fully-functional mode in which the graphical user interface displays formatting fields, processing options, menus and the processing icons, and (2) a minimizing mode in which the graphical user interface displays on ly the processing icons. Typically, the graphical user interface displayed in the minimizing mode is displayed during browsing the hypermedia document. By displaying the graphical user interface in plural modes, the present invention facilitates operation of the invention during browsing of the hypermedia document.

This summary has been provided so that the nature of the invention may be understood quickly. A more complete understanding of the invention can be obtained by reference to the following detailed description of the preferred embodiments thereof in connection with the attached drawings.

DETAILED DESCRIPTION OF THE PR

#### EFERRED EMBODIMENT

Pigure 1 is a view showing the outward appearance of a representative embodiment of the invention. Shown in Figure 1 is computing equipment 1, such as a MacIntosh or an IBM PC or a PC-compatible comput

(1.9)

er, having a windowing environment, such as Microsoft Windows. Provided with computing equipment 1 is display screen 2, such as a color monitor or a monochromatic monitor, keyboard 3 for entering text data and user commands, and a pointing device such as mouse 4 for pointing and for man ipulating objects displayed on display 2. Computing equipment 1 also in cludes a mass storage device such as disk drive 5. Image data can be in put into computing equipment 1 from a variety of sources such as a network interface 11a or from external devices via facsimile/modem interface 6. Network interface 11a is used to connect computing equipment 1 to a local area network (LAN) or to a wide area network (WAN) such as the World Wide Web.

Figure 2 is a detailed block diagram showing the internal construction of computing equipment 1. As shown in Figure 2, computing equipment 1 includes central processing unit (CPU) 8 interfaced with computer bus 9. Also interfaced with computer bus 9 is printer interface 10, fax/modem interface 6, display interface 11, network interface 11a, k cyboard interface 12, mouse interface 13, main memory 14, and disk drive 5.

Nain memory 14 interfaces with computer bus 9 so as to provide random access memory storage for use by CPH 8 when executing an application such as personal news profile editor 16 or Web printer 17. More specifically. CPH 8 loads these software applications from disk drive 5 into main memory 14 and executes the software applications out of main memory 14. In accordance with user instructions, stored application programs are activated which permit processing and manipulation of data. Typically, the software applications stored on disk drive 5, such as per sonal-news-profile editor 16, Web printer 17, and HTML formatter 18, have been stored on disk drive 5 by downloading the software applications from a computer-readable medium such as a floppy disk or CD ROM, or by do

<u>(2.0)</u>

wnloading the software applications from a computer bulletin board.

Disk drive 5 stores data files which can include text file s and image files, in compressed or uncompressed format, and stores soft ware application files such as those noted above. The software applicat ion files include Windows applications, DOS application, and personal ne ws retrieval files 15. Personal news retrieval files 15 include persona 1-news-profile editor 16, Web printer 17, HTML formatter 18, personal-ne ws-profile(s) 19, and site profile(s) 20. The detailed functions of per sonal news retrieval files 15 will be discussed below, after a brief ove rview of the operation of the personal new retrieval system.

Overview of Document Retrieval

Figure 3. comprised of Figures 3A to 3D, illustrates the o peration of a representative embodiment of the invention. Figure 3A is a graphical representation of a typical Web site 21 with news informatio n contained therein. Within Web site 21 is homepage 22 with links to in dices such as headings 23, which are in turn linked to articles 24. c of articles 24 are linked to other articles. As article H 26 resides on another Neb site, link 25 is a cross-site link. Link 25 illustrates how a single hypermedia document, represented by homepage 22, can traver se multiple Web sites.

In order to retrieve news from Web site 21, the invention first traverses Web site 21 to retrieve data according to user-defined r ules. As will be discussed in more detail below, these rules can be bas ed on the structure of Web site 21, or on the structure of Web site 21 a nd its contents. The data is retrieved into an extracted data tree, whi ch preserves the organization of the data as shown in Figure 3B, but in which some links are excluded.

The organization of extracted data tree 27 has several fea First, extracted data tree 27 has root 28 which can have child n tures.

odes for one or more sites 29, which in turn can have index nodes 30 which correspond to indices/headings 23, articles nodes 31, and the like. Second, extracted data tree 27 is a true tree, with no loops (i.e., cyclic paths) therein. For example, Figure 3A shows a loop from homepage 22 to index node \$1, to article C, and then back to homepage 22. This loop is removed when creating extracted data tree 27.

Second, the organization of extracted data tree 27 depends on how the Web sites are traversed, and not on the Neb sites' actual la youts. Thus, article H 26 appears under index node #3 (under site #1), indicating that the news retrieval system accessed article H 26 from sit e #1 via cross-site link 25.

Finally, as noted earlier, certain articles have been excluded from extracted data tree 27 due to the structure of Web site 21 or possibly a content of indices/headings 23 and articles 24. For example, articles B and G have been excluded from extracted data tree 27.

According to the invention, extracted data tree 27 is flat tened into linear document 32, as shown in Figure 3C, possibly with reference to more exclusion rules. Linear document 32 is simply a continuous document with information from extracted data tree 27 embedded therein

Finally, linear document 32 is formatted according to user specified (or default) formatting instructions into formatted document 33, shown as a stylized personal newspaper in Figure 3D. Formatted document 33 has various fonts and/or colors for site labels, indices/heading s, articles, and the like. Furthermore, formatted document 33 is broken down into pages.

Note that in alternate embodiments of the news retrieval system, certain stages of the above transformation from Web site 21 to formatted document 33 can be skipped. For example, data from Neb site 21

can be retrieved directly into flattened document 32, as long as a record of the organization of the data is maintained (possibly in a separate linked list) so as to avoid downloading the same article twice and so as to avoid loops in the organization of Web site 21. Alternatively, extracted data tree 27 can be directly formatted into formatted document 33.

In any case, the basic operation of the invention remains the same: the news retrieval system traverses a hypermedia document on the Web, extracts data according to user-defined information, and formats the data into a personalized newspaper.

As mentioned in the above discussion, various user-defined rules and other information (such as formatting information) are involved in the news retrieval process. That user defined information is stored in personal-news-profile(s) 19, the definition of which is described next.

Defining a Personal-News-Profile

Figures 4 and 5 illustrate the process by which personal-news-profile 19 is defined. To create personal-news-profile 19, personal-news-profile editor 16 communicates with personal-news-profile 19, site profile 20, and Web reader 34.

Personal-news-profile 19 contains information as to what s ites to access for creating a personalized newspaper, what sections to r etrieve from those sites, rules to be used to determine what data to ext ract from the sections and the articles therein, rules to determine how to exclude links, and newspaper format information. A sample personal-n ews-profile is shown in Appendix 1.

Site profile 20 includes general site information that is not specific to a particular user. For example, site profile 20 could contain information such as full site addresses, sections within a site, non-user specific passwords, etc. Sample site profiles are shown in App

ile.

(23)

endix 1. Because general site information is stored in site profile 20, personal-news-profile 19 can refer to the general site information with reference to site profile 20, saving space in the personal-news-profile. For example, as shown in Appendix 1, personal-news-profile 19 can refer to a site number 1. Site profile 20 indicates that site number 1 is the "San Jose Mercury News," with a homepage at "http://www.sjmcrcury.com/". This construction also centralizes general site information. Thus, if a site address changes, only site profile 20 needs to be changed to update all personal-news-profiles 19 on the system.

Web reader 34 is an application program or program module that communicates with the Meb via Neb server 35. In response to commands from personal-news-profile editor 16. Web reader 34 will access the Web, traverse hypermedia documents on the Web, retrieve data from the documents, and return the retrieved data to personal-news-profile editor 16

As shown in Figure 4, personal-news-profile editor 16 includes four modules: site driver 36. Web reader interface 37, profile manager 38, and format editor 39.

Web reader interface 37 interfaces personal-news-profile editor 16 to Web reader 34. Site driver 36 interacts with Web reader 34 via Web reader interface 37 to provide an abstract interface to each individual Web site. More specifically, site driver 36 instructs Web reader 34 to access various Web sites and to retrieve data from those sites. Thereafter, site driver 36 receives that data and builds site profile 20 therefrom. The data can also be used to update an existing site prof

In building site profile 20, site driver 36 translates the structure of each accessed Web site to a uniform structure defined in site profile 20, and stores data retrieved therefrom in site profile 20.

(24)

By translating different Web sites, some of which may have different s tructures, into a single uniform structure and storing data therefrom in that structure in site profile 20, the present invention facilitates access to information from different Neb sites, and thus reduces overall p rocessing time.

Profile manager 38 maintains document templates that specify how to format a personalized newspaper. Predefined document templates exist. In addition, format editor 39 allows a user to specify personalized templates for formatting a newspaper, either by editing existing templates or by creating new ones. In any case, each document templates pecifies page layout information, font information, style information, colors, etc. for the titles, indices/headings, subheadings, text and the like for a personalized newspaper.

Sample code for personal-news-profile editor 16, site driver 36, and profile manager 38 is included in Appendix 3A.

Figures 5A and 5B are flow diagrams describing the operation of personal-news-profile editor 16 in more detail. Figure 5A shows the operation of personal-news-profile editor 16 in defining the parts of personal-news-profile 19 relating to accessing Web sites and retrieving data from those sites.

In step \$500 of Figure 5A, personal-news-profile editor 16 is launched by a user. In step \$501, the editor launches Web reader 34. The user's personal I.D. is then retrieved in step \$502. If a person al-news-profile already exists for that I.D., utep \$503 directs flow to step \$504, where the user is given the option of skipping to the format editor. Otherwise, personal-news-profile editor 16 enters a "learning mode" in step \$505. Once in the learning mode, personal-news-profile editor 16 proceeds to step \$506, where it accepts a Web command (i.e., a command to traverse a hypermedia link) from the user and forwards the Web

(25)

command to the Web reader by means of site driver 36. Site driver 36 maintains a hierarchical log of Web sites visited by Web reader 34. In step \$507, personal-news-profile editor 16 creates an extraction rule from the Web command. This rule will allow the news retrieval system to later duplicate the user's selection criteria in browsing (clicking on hyperlinks within) a Web site.

The rule specifies, at the least, structural criteria for duplicating the traversal of the Web site. For example, if a user accesses all articles under a particular index/heading, the rule will specify that all articles under that index/heading should be retrieved.

In one embodiment of the invention, the rule can also include content-based criteria (i.e., keyword-based criteria) accepted from the user. These content-based rules can, for example: (1) require certa in words to be in an article, (2) exclude articles with certain words, (3) require certain boolean combinations of words, (4) rank articles that are selected based on structural criteria, with the ranking based on keywords, and then require the selection of the articles with the highest ranking(s), or (5) exclude certain types of articles such as advertisements.

Examples of the syntax for the structural and content-base d exclusion rules are shown in Appendix 2. Several different types of rules are shown. Some simply limit the traversal of a Neb site to a cert ain number of links. Others are date and keyword based exclusion rules.

One particularly flexible rule indicates that articles should be ranked based on a keyword analysis and the top scoring articles should be chosen. Other rules include "flattening" rules. These rules control the flattening of the extracted data tree, as will be explained in more detail below.

At the least, the rule includes structural information abo

(26)

ut the user's selection (i.e., first page, first document, all links, et c.), necessary password information, browser commands, and the like. The rule can also include a pointer or a reference to site profile 20 and the appropriate information therein. General (non-user specific) information is used by site driver 36 to maintain site profile 20. In this manner, address information and passwords common to multiple users can be maintained in site profile 20, as discussed above. For example, site driver 36 will store commands or hyperlinks to other documents in a Web page in the rule, but will not store a Web site's full address in the rule. That address information is stored in site profile 20.

In step S508, rule data defining the rule created from a W eb command(s) is stored in an extracted data tree such as extracted data tree 27 in Figure 3B. This data tree is a linked list that reflects the organization of the data retrieved from the Web. In step S509, flow r eturns to step S506 for the next Web command unless the user is done (i. e., the user signs off the Web site), in which case flow proceeds to step S510.

At this point, the creation of the personal-news-profile has proceeded much like the creation of a macro common to word processing programs, except that site profile 20 has been used to minimize storage requirements and to centralize general site information. In order to minimize storage requirements further and in order to make the news retrieval system more flexible and efficient, the extracted rules are now compiled to remove redundant links, multiple visits to the same site, and the like. This occurs in step S510, and the resulting compiled rules become the first part of personal-news-profile 19.

Alternatively, personal-news-profile editor 16 may be invoked as a graphical user interface which allows a user to edit a previous ly stored personal-news-profile or to specify document composition prefe

(27)

rences, for example, by specifying news sites, headline articles only, k eywords, etc. In either case, the result is personal-news-profile 19, w hich comprises a listing of Web site pointers as well as extracted rules for traversing through a Web site or sites.

For a better understanding of the above, sample personal-n ews-profiles and sample site profiles are provided in Appendix 1 as note d above.

Next, operation proceeds to give the user an option to mod ify a custom newspaper template, as shown in Figure 58. In step S511, it is determined if a newspaper template has been defined and stored in personal-news-profile 19. If a newspaper template has been defined, step S512 gives the user the option to edit the template or to proceed to step S520. If the user chooses to edit the template or if no newspaper template has been defined, flow proceeds to step S513.

Step S513 gives the user the option of creating a custom t emplate or using a predefined template. If the user wants to use a predefined template, step S514 gets the specified predefined template, which is added to the personal news profile in step S519. Otherwise, flow proceeds to step S515, where format editor 39 is invoked.

Format editor 39 has a graphical user interface that provides the user with a number of formatting options. In step S516, format editor 39 allows the user to define which newspaper sections are to be printed in the newspaper, which Neb site's news article are to be placed in each section, and/or how each page is to be laid out. In this regard, the user can specify which Web site's news articles are to be used as a front page, which Web site's news articles are to be used as a busines a page, which Web site's news articles are to be used as a sports page, etc. In addition, in step S516, the user can define where each index/he ading should be listed, as well as what sub-headings should go on each p

(28)

age.

any time.

In step S517, format editor 39 allows the user to define the font styles for indices/headings, sub-headings, bylines and actual text of news articles. In step S518, format editor 39 prompts the user to define index/heading colors, title colors, etc. In this regard, layout editor 39 is capable of determining the types of fonts and colors available to the user based on the system's printer capabilities.

Once all of the information is gathered for the custom template, the format editor adds the information to personal-news-profile 19 in step S519. Alternatively, profile manager 38 may also store the custom format as a template in a common area for use by other users. In this case, only a pointer or reference to the custom template is stored in personal-news-profile 19.

In step S520, personal-news-profile editor 16 prompts the user to set an automatic newspaper delivery time and method (i.e., print or store on disk drive 5 for later printing). These settings are added to personal-news-profile 19. More specifically, in the case that a use r's computer is continuously supplied with power, the Web news retrieval system can be launched automatically at a designated time. The system will retrieve articles from the Web sites which are listed in personal-news-profile 19. Upon retrieving the news articles, the articles will be formatted based on the newspaper template in personal-news-profile 19. The formatted personalized newspaper can then be either printed or sto red for later viewing. In the case that a time is not set for newspaper

Unce personal-news-profile 19 has been created, the Web news retrieval system, upon being launched, can traverse Web news sites and build a personalized newspaper by automatically retrieving various new

delivery, the user can execute the Web news retrieval system program at

(29)

s articles from the Web news sites and print the news articles based on the newspaper template indicated in personal-news-profile 19. A descrip tion of how the Web news retrieval system of the invention performs this function is described next.

Retrieving a Document Using a Personal-News-Profile

Figure 6 is a representational block diagram of the manner by which the invention retrieves articles from the Web according to per sonal-news-profile 19. (Figure 6 also shows the manner by which the ret rieved articles are flattened into a linear document and formatted. The se functions are discussed in greater detail in the next section of this application.)

As shown in Figure 6, Web printer 17 is responsible for retrieving news articles. Web printer 17 is an end-user application that communicates with personal-news-profile(s) 19, site profile 20, Web read er 34, and output interface 40 in order to perform this function.

Web printer 17 looks at personal-news-profile 19 to determ ine which Web sites to access and which data to retrieve from those site s. Web printer 17 also looks at site profile 20 for general site information. According to the information in personal-news-profile 19 and sit e profile 20, Web printer 17 instructs Web reader 34 to connect to the Web via Web server 35 in order to access various Web sites and to retrieve data from those sites. Web reader 34 sends the retrieved data to Web printer 17, and Web printer 17 uses the data to build an extracted data tree. As will be discussed in greater detail in the next section of the application, Web printer 17 then flattens the extracted data tree into a linear document and formats the linear document for output via output interface 40.

As shown in Figure 5, Web printer 17 includes four program modules: Web reader interface 50, site driver 51, tree manager 41, and

(30)

formatter 42.

Web reader interface 50, like Web reader interface 37 described above, interfaces Web printer 17 to Web reader 34.

Site driver 51 accesses site profile 20 and personal-news-profile 19 and provides data stored therein to Web reader 34. As noted above, Web reader 34 uses that data to access various Neb sites and to extract data therefrom. As noted above, this retrieved data is used by Web printer 37 to build an extracted data tree.

Tree manager 41 manages the extracted data tree. In this regard, tree manager 41 keeps track of the organization of the retrieved data in the extracted data tree. This allows Web printer 17 to avoid a coessing the same article twice, to avoid unnecessarily re-visiting a Web site, and to avoid getting caught in a cycle (loop) in the organization of a hypermedia document on the Web. Alternatively, tree manager 41 could store the data in blocks (as opposed to directly in a data tree) with reference to a linked list that provides the same functionality as the extracted data tree. Sample code for tree manager 41 is included in Appendix 38.

Formatter 42 is responsible for flattening the extracted d ata tree into a linear document and formatting the linear document into a personalized newspaper. Formatter 42 performs these functions in accordance with the print criteria and format information (i.e., newspaper t emplate) indicated in personal-news-profile 19. Sample code for formatter 42 is included in Appendix 38.

In more detail, Figure 7 is a flow diagram describing how Web printer 17 uses Web reader 34 to traverse the Web according to personal-news-profile 19 and to retrieve articles from the Web according to the profile, excluding unwanted data.

The Web printer starts in step S700. In step S701. Web pr

(31)

inter 17 retrieves either a user designated personal-news profile or a default personal news profile stored in disk drive 5 using site driver 51. In this regard, because computer equipment 1 may be used by more than one user, there may be one or more personal news-profiles stored on the equipment, one of which will be designated as the default. Upon retrieving the designated personal-news-profile, in step \$702 Neb printer 17 determines whether any news data has been previously stored to disk drive 5 (for example, by a previous automatic news delivery) or if news articles should be retrieved using personal-news-profile 19.

In the case that news data does exist on disk drive 5, in step S703 the stored news data is retrieved and flow proceeds to step S8 01 of Figure 8, discussed in more detail in the next section. On the other hand, if no stored news data exists, Web printer 17 invokes Web reader 34 in step S704. Note that this is the same Web reader 34 as discussed above with respect to defining a personal-news-profile.

Upon being invoked, Web reader 34 connects to Web server 3 in step \$705, which provides a connection to a network, such as the World Wide Web. Web printer 17 then provides Web reader 34 with an address for the first Web site to be visited based on information retrieved from personal-news-profile 19. Once connected to the desired Neb site in step \$706, Web printer 17 provides Web reader 34 with commands/links for traversing the Web to the next Web page containing information that per sonal-news-profile 19 indicates should be retrieved. Web reader 34 traverses the Web according to this information in step \$707.

In step S708, Web reader 34 retrieves the desired information and sends it to Web printer 17 according to the rules in personal-news-profile 19. Thus, data exclusion occurs in this step. The rules in personal-news-profile 19 specify structural and content-based criteria for excluding data from the personalized newspaper. The structural rules

(32)

limit the retrieved information on the basis of the structure of the We b site accessed by Web reader 34. The content based rules limit the retrieved information on the basis of its content. As mentioned above with respect to creating a personal-news-profile, examples of the syntax of the retrieval rules in personal-news-profile 19 are included in Appendix 2.

In addition to rule-based exclusion, media-type exclusion occurs in step \$708, wherein data of a media type that can not be printe d is excluded from the extracted data tree. For example, movie and sound data can be excluded.

Neb printer 17 stores the retrieved data in disk drive 5 (or in main memory 14) in the extracted data tree managed by tree manager 41. Alternatively, the data could be stored in blocks with reference to a linked list, as discussed earlier. In step S709, Web printer 17 returns to step S707 to complete retrieving all information from Web pages at the Web site. In step S710, upon completing a traversal of one Web site, Web printer 17 uses tree manager 41 to compare the sites remaining in personal-news-profile 19 with the site organization information in the extracted data tree to determine if more sites need to be visited. In the case that more Web sites need to be visited, step S710 returns flow to step S706 and news articles are retrieved in the same manner as discussed above. On the other hand, if all of the Web sites listed in personal-news-profile 19 have been visited and all of the articles retrieved, flow proceeds to step S801 in Figure 8.

Flattening and Formatting the Retrieved Data

Figure 8 is a flow diagram showing how the extracted data tree is flattened and formatted. The configuration of the invention is the same as when retrieving data from the Neb (shown in Figure 6). In fact, the flattening and formatting processes can occur, at least to a li

(33)

mited extent. concurrently with the data retrieval process.

In step \$801 of Figure 8, the extracted data tree is flatt ened. This simply means that the organization of the data is converted from an extracted data tree to a linear document. This step provides the opportunity for excluding more data from the personalized newspaper, for example by only including nodes of the data tree into the flattened document. This exclusion process is controlled by the flattening rules in personal-news-profile 19.

After the data is flattened into a linear document, the data is formalled in step S802 according to the template indicated in personal news-profile 19. The definition of this template, which is either a pre-defined template or a custom template, was discussed earlier. Fin ally, in step S803, the formatted and fully personalized newspaper is sent to output interface 40. This interface could be printer interface 10 to printer 7. display interface 11 to display 2, or even modem/fax interface 6.

Second Embodiment: The HTML Formatter

The second embodiment of the invention is a system for processing a hypermedia document. The system accesses the hypermedia document, extracts addresses from the hypermedia document, and stores the addresses extracted from the hypermedia document in a container. The system activates a processing function to process data stored at the addresses stored in the container, downloads the data stored at the addresses stored in the container into a memory, and extracts predetermined data from downloaded data in accordance with predetermined configuration information. The predetermined data is then formatted in accordance with predefined formatting settings to generate a formatted document, and the formatted document is processed in accordance with the processing function.

The second embodiment of the invention is depicted as HTML

formatter 18, noted in Figure 2. An example of HTML formatter 18 is We bformatter, manufactured by Canon Information Systems, Inc. The second embodiment will be described with respect to WebFormatter. It should be noted, however, that HTML formatter 18 is not limited to the WebFormatter embodiment, and that various alternative embodiments within the spirit and scope of the following description are possible.

Wehlformatter is stand-alone utility software that can be u sed in conjunction with different Web browsers, such as Netscape, Mosaic and Internet Explorer. In short, WebFormatter extracts data from a Web page, strips out extemporaneous data from the extracted data, and reformats the data into a formatted document. The formatted document can the n be printed, stored in an RTF (Rich Text Pormat) file, or edited in any RTF compatible editor, such as NS Word, WordPerfect, Wordpad, etc.

WebFormatter can be activated from a windowing environment, such as Microsoft Windows(r). From such a windowing environment, WebFormatter can be activated by double-clicking on a WebFormatter icon (not shown) in a start-up window, selecting WebFormatter from the Windows start menu, dragging a URL (uniform resource locator) icon (not shown) from a Web browser and dropping it into the WebFormatter icon, or by automatically invoking WebFormatter when the Web browser is started.

Unlike the first embodiment of the invention described above. WebFormatter does not use a predefined personal-news-profile to specify criteria for creating a particular type of document from one or more Web pages. Rather, WebFormatter relies upon user-specified criteria to create a particular type of document, such as a newspaper or the like, from one or more Web pages. These criteria are input interactively by a user via a graphical user interface.

As described in more detail below, WebPormatter operates in two modes — a minimized mode and a fully-functional mode. In the mini

#### <u> 整理番号=36 P 1 1 1 J</u>

(35)

mized mode. WebPormatter's graphical user interface is essentially a flo ating print button, which is displayed concurrently with displayed Web p ages. By virtue of this feature, as a user explores the Web, the user c an process, format, and print out Web pages by mcrely clicking on the floating print button.

In its fully-functional mode, WebFormatter's graphical use r interface provides spaces for a user to enter a URL address of a Web p age to be processed, enter a personal title for the document, select a f ormat for the document, preview a formatted first page of the document, and either print the document, save the document as an RTF file, or view /edit the document using an RTF editor. The graphical user interface for the fully-functional mode will be described first, since it is from th at interface that the user can enter the minimized mode.

Figure 9A shows graphical user interface 43 for WebFormatt er's fully-functional mode. Graphical user interface 43 is displayed on display 2 upon first activation of WebFormatter. As with any interactive windowing software application, a user interacts with graphical user interface 43 by means of mouse 4 (by pointing and clicking) and keyboard 3.

As shown in Figure 9A, graphical user interface 43 include s fields 44 and 46 to 49, through which a user can specify the URL address of a document to be formatted and the format of that document. Begin ning with URL field 44, a user enters the URL address (e.g., http://www.cis.canon.com/tis/tis\_home.htm) of a Web page to be processed by WebFor matter. There are several different ways for the user to enter the URL address. The user can (1) type the address directly into URL field 44, (2) copy the URL address in the Web browser and paste the URL address in to URL field 44, (3) drag the URL address from the Web browser onto grap hical user interface 43 or onto the WebFormatter icon, or (4) click on C

(36)

urrent URL button 54.

With regard to Current URL button 54, if a user clicks on Current URL button 54, WebFormatter locates the active Web browser and queries the Web browser for the address of the current Web page. Thereafter, the Web browser provides the address of the current Web page to Web Formatter, which places the address in URL address field 44. If URL but ton 54 is activated and no Web browser is currently running, NebFormatter displays dialog box 56, shown in Figure 9A.

As shown, dialog box 56 includes Cancel button 57 and Laun ch Browser button 59. Cancel button 57 cancels a user's request to input a URL address into URL address field 44 via Current URL button 54. La unch Browser button 59, on the other hand, launches a Web browser specified in WebFormatter. As noted below, WebFormatter is configured beforeh and with predefined information including a Web browser to be used with WebFormatter. Configuration of WebFormatter will be described in more detail below.

In alternative embodiments of WebFormatter, a filename can also be entered into URL address field 44. For example, in these alter native embodiments, if a user wishes to format a hyper linked manual int o a book-like format, the user enters the filename into URL address field 44. Thereafter, WebFormatter proceeds through the file in the same manner as through specified Web pages in order to reformat the hyper-linked manual as desired.

Returning to graphical user interface 43, title field 46 e nables a user to enter a personalized title for a formatted document. The title may be typed directly or pasted into title field 46.

Formatting fields 47 to 49 define the format of a document to be output by WebFormatter. Options for the different formatting fields can be accessed by clicking on a scroll bar, such as scroll bar 55,

(37)

of a respective formatting field. Each of these fields is described in detail below.

Styles field 47 provides four options for formatting an output document. These styles relate to characteristics of an output document such as size of headers, margins, etc. The style options include C ontemporary, Formal, Fun and Professional. The invention, of course, is not limited to these four style options, and other styles can be added as desired.

Columns field 48 defines the number of columns in a format ted output document. Two columns options are available — Single and Multiple; however, the invention is not limited to these two options. The Single option, as might be expected, formats the document into a single column. The Multiple option, on the other hand, formats the document in to a predetermined number of columns. In preferred embodiments of the invention, the multiple option is set to two columns; however, any number can be set.

Spacing field 49 defines the spacing between lines in a formatted output document. Three options are provided in WebFormatter, but other options can be added as desired. These three options are Condensed, Normal and Easy To Read, with Condensed being the least amount of spacing between lines and Easy To Read being the most amount of spacing between lines,

Graphical user interface 43 is also provided with Preview button 60. By clicking on Preview button 60, a user can preview a first page of a formatted document in viewing area 61. An example of a previewed formatted document is shown in Figure 9A.

As shown in Figures 9A and 9B. WebFormatter also includes Options button 61. Options button 61 provides a user with additional formatting options which are used by WebFormatter to create a formatted do

(38)

cument. A user can activate Options button 61 by clicking thereon. This causes Options dialog box 62, shown in Figure 9B, to appear on display 2.

As shown in Figure 9B, options dialog box 62 includes Gene ral options 64, Container options 66 and Strip Meta Info options 67. General options 64 includes "Text only" listbox 72, "Index of links in the page" listbox 73, and "No floating pictures" listbox 74. These options are indicated as being selected by a check mark or the like in a respective listbox. As will become clear from their descriptions, more than one of the options in General options 64 can be selected at the same time

"Text only" listbox 72 instructs WebFormatter to strip all graphics in a Web page and print only text therein. "Index of links in the page" listbox 73 instructs WebFormatter to add a list of all URLs p resent in a Web page or pages to the end of a formatted document. Preferably, the list of URLs is printed as superscript, and anchor positions of the URLs in the list are marked in bold. "No floating pictures" list box 74 instructs WebFormatter to print all images in the document in a p articular area of the formatted document. In some cases, therefore, when this option is selected, WebFormatter shrinks images, as needed, so that images fit into a particular area.

Strip Meta Info options 67 provides engineering options which facilitate stripping of unnecessary information from a Web page being processed by WebFormatter. The options include (1) "None", which instructs WebFormatter to strip nothing from the Web page, (2) "Till the first horizontal rule", which instructs WebFormatter to strip all links and images until and up to predefined first and second horizontal formatting rules (e.g., up until a horizontal line across a page), and (3) "Till the first text", which instructs WebFormatter to strip all links and images until a horizontal webFormatter to strip all links and images until the first text".

(39)

ges up to first and last occurrences of text in the Web page. Only one of Strip Meta Info options 67 can be selected at a time. Selection thereof is indicated by a dot in a bullet located next to an option, as shown in Figure 9B.

Container options 66 provides options for processing documents, addresses for which are stored in container 76 shown in Figure 98.

Prior to describing Container options 66, a description of container 76 will be provided.

As noted, container 76 stores URL addresses of selected do cuments. Document addresses which are input to field 44 are added to container 76. The order in which URLs are input into container 76 denotes the order in which data in the URLs is processed by WebFormatter. As shown in Figure 9B, once container 76 becomes full, its icon changes to that shown by reference numeral 77.

When a user clicks on the icon for container 76, menu 77 is displayed. Menu 77 provides five options: i.e., Open 79. Empty 80. Pr int 81, Edit 82 and Save 84. These options are highlighted when activated, and are described in detail below.

Open 79, when activated, displays Container Contents screen 87 shown in Figure 98. Container Contents screen 87 shows the URL add resses stored in container 76. Container contents screen 87 provides four buttons; i.e., Add current URL button 88 which adds the current URL to container 76. Delete button 89 which permits a user to highlight and delete a URL in container 76. Empty button 90 which permits a user to empty container 76, and Done button 91 which permits a user to close Container Contents screen 87. It is noted that a user can also empty the contents of container 76 by clicking on Empty 80 of menu 77.

In addition, the user can rearrange the order of URLs stored in container 76 by dragging and dropping different URLs at different

#### 

(40)

locations therein. As noted above, since the URLs are processed in the order that they appear in container 76, this feature permits a user to rearrange the

processing order of the URLs in container 76 interactively.

Print 81, Bdit 82 and Save 84, when activated, cause WebFo rmatter to download all data at Web pages defined by the URLs stored in container 76, format them as specified by the user, create RTF file(s) s toring the formatted Web pages, and do the selected action, i.e., save, edit or print the RTF file(s). This process is described in greater detail below.

Referring back to Options dialog box 62, Container options 66 include "Print table of contents" listbox 92 and "Empty after processing" listbox 94. As shown, a check mark appears in a listbox to indicate that the listbox has been selected. In this regard, more than one listbox can be selected at a time. "Print table of contents" listbox 92, when selected, instructs WebFormatter to print titles of all ERLs in container 76 as a table of contents in a formatted output document. "Empty after processing" listbox 94, when activated, instructs WebFormatter automatically to empty container 76 after printing, editing or saving a document, without waiting for a user to do so.

Also shown as part of Container options 62 are Select RTF Editor button 69, Cancel button 70 and DK button 71. By clicking on Select RTF Editor button 69, a user can select an RTF file editor, examples of which are noted above. This can be done, for example, by displaying another dialog box listing predefined RTF editors (not shown) and selecting one of the predefined RTF editors. Cancel button 70 cancels Container options 62 and OK button 71 confirms selected options in Container options 62 and then closes its dialog box.

As shown in Figure 9B, graphical user interface 43 also in

(41)

cludes print icon 96, edil icon 97, save icon 99, help hutton 100, done button 101 and minimizing icon 102. A user may select any of these features by clicking thereon using a mouse.

Print icon 96 opens a print dialog box (not shown), which allows a user to print any number of copies of Web pages formatted by Web Formatter. Edit icon 97 opens an RTF file storing formatted Web page(s) for editing by a predetermined RTF editor. Save icon 99 opens a save dialog box (not shown), which allows the user to name and save a formatted Web page as an RTF file. Help button 100 provides help messages for operating WebFormatter, and Done button 101 exits from WebFormatter. Minimizing icon 102 activates the minimizing mode of Webformatter which was mentioned above and which is described in greater detail below.

Figure 9C shows menus provided by WebFormatter during its operation. These menus include file menu 103, edit menu 104 and window menu 106. File menu 103 provides "Save", "Edit" and "Print" options, the functions of which are identical to those of Save icon 99, Edit icon 97, and Print icon 96, respectively. An "Exit" option is also provided to exit from File menu 103. Finally, File menu 103 provides "Open HTML file" option 107. This option provides a user with the capability to open a local HTML file; i.e., a hypermedia file resident on the user's computer such as a file saved from NetScape, or URL files created by dragging and dropping a URL onto the windows desktop. "Open HTML file" option 107 also provides hooks needed to open files created by other Web-file-processing products so that those files can be formalted as RTF files and printed, saved and/or edited using WebFormatter.

Bdit menu 104 provides "Paste URL" option 109. "Paste URL" option 109 pastes the contents of a paste buffer, such as a URL address copied from a Web page, into URL field 44, as described above.

Window menu 106 provides a "Help Topics" option which prov

### 

(42)

ides a user with information regarding the use, maintenance and background of WebFormatter, and an "About WebFormatter" option which provides a user with a dialog box (not shown) containing WebFormatter's version number and copyright notice(s). Window menu 106 also includes "Preferences" option 110. "Preferences" option 110 opens preferences dialog box 112, shown in Figure 9D.

Preferences dialog box 112 is used to configure and re-con figure WebFormatter. As shown in Figure 9D, preferences dialog box 112 includes Minimize view options 113. General options 114 and WWW Browser to use options 115. Minimize view options 113 can be set to configure WebFormatter's graphical user interface in the minimized mode. Two sets of options are provided. The first set include "Print", "Edit" and "Save". These options correspond to print icon 96, edit icon 97 and save icon 99, shown in Figure 9B. When a check mark appears in a listbox next to one of these options, the icon for that option is displayed in the minimized mode, e.g., the print icon, the edit icon and/or the save icon.

More than one option can be selected at once. In this regard, Figure 98 shows graphical user interface 116, which is a representative example of a graphical user interface for WebFormatter when WebFormatter is in the minimized mode.

Referring back to Figure 9D, Minimize view options 113 also include "Row" and "Stack" options. These options can be set to display WebFormatter's graphical user interface in the minimized mode horizontally by selecting "Row" or vertically by selecting "Stack". Only one of these options can be selected at a time. As an example of the foregoing, graphical user interface 116 corresponds to a row of icons.

WWW Browser to use options 115 determine which World Wide Web browser is to be used with WebFormatter. As shown, preferably NetSc

ape, Internet Explorer and Mosaic are provided as browser options; however, other browser options can also be provided. As might be expected, only one of these options can be selected at a time. The default browser option is NetScape Navigator.

General options 114 include "Auto-start with browser" opti on 117, "Open in minimized view" option 118, "Warn before printing more than \_\_ pages" option 119, and "Warn before saving more than \_\_ MBs" opt ion 120. "Auto-start with browser" option 117 sets WebFormatter to be i nvoked automatically when a Web browser is activated. If this option is not selected (which is the default), WebFormatter is opened by double c licking on a WebFormatter icon in the windowing environment, selecting W ebFormatter from the Windows start menu, or dragging and dropping a URL from the Web browser into the WebFormatter icon, as described in more de tail above. "Open in minimized view" option 118, when selected, opens W ebFormatter in minimized mode. The default, however, is the fully-funct ional mode. "Warn before printing more than \_ pages" option 119, and " Warn before saving more than \_\_ MBs" option 120 allow a user to control the number of pages saved of a formatted document and the amount of memo ry space used by those pages, respectively. The default for both of the se options is for no warning to be given. As is evident, more than one of the general options can be selected at the same time.

Preferences dialog box 112 also includes cancel button 121 which cancels a user's selected preferences and DK button 122 which confirms a user's selected preferences.

As explained above, WebFormatter can be configured to enter directly into the minimized mode via Preferences dialog box 112, or a user can enter the minimized mode via minimizing icon 102 shown in Figure 98. As also noted above, Figure 98 shows an example of graphical user interface 116 for WebFormatter in the minimized mode. Graphical user i

#### <u>整理番号 - 36 P 1 1 1 J</u>

(44)

nterface 116 is displayed as a floating interface while a user is exploring the Web. Thus, as a user views a Web page, the user also views graphical user interface 116. By clicking on an appropriate icon on graphical user interface 116 (which, in Figure 9E, includes icons identical in both structure and function to those shown in graphical user interface 43), the user can capture the current Web page, process and format the Web page into an RTF file, and save, edit and/or print the RTF file. Alternatively, the user can drag a URL from the Web browser and drop it into one of the icons.

A user can reconfigure WebFormatter in the minimizing mode by double clicking a right mouse button. This action causes a preferences dialog box to appear on display 2 which is identical to preferences dialog box 112. Thereafter, the user can alter the configuration of WebFormatter as desired. Should a user wish to enter the fully-functional mode from the minimizing mode, the user need merely click on maximizing icon 117 shown in Figure 98.

Figure 10 is a flow diagram describing the operation of We bFormatter. WebFormatter is activated in step \$1000. As described above, this can be done by double-clicking on a WebFormatter icon in a windowing environment. Depending upon how WebFormatter has been configured, i.e., in the fully-functional mode or the minimizing mode, either a graphical user interface similar to that of graphical user interface 43 or one similar to that of graphical user interface 43 or one similar to that of graphical user interface 116 is displayed in step \$1000. For the sake of completeness, the following assumes that a graphical user interface similar to that of graphical user interface 43 is displayed in step \$1000, since the default mode of WebFormatter is the fully-functional mode.

Next, in step S1001, WebFormatter is configured, as described above via preferences dialog box 112 and options dialog box 62. Thi

(45)

s step is not necessary unless a user wishes to change NebFormatter's previously set configuration. In step S1002, document format data is input in fields 44 and 46 to 49 described above. More specifically, the user inputs a URL (or filename in alternative embodiments) into URL field 44. As described below, WebFormatter uses this information to process Web pages stored at the URL to create an RTF file based on the configuration of WebFormatter and the data input in fields 46 to 49.

In step S1003, a Web reader similar to that of Web reader 34 described above is executed. The Web reader connects to a network, such as the World Wide Web, in step S1004.

Next in step \$1005, it is determined whether a URL or a filename has been entered. As described above, in preferred embodiments of WebFormatter, only a URL may be entered. However, since alternative embodiments of WebFormatter may permit entry of a filename, a description of processing a file other than one at a URL address will be provided.

If a URL has been entered in field 44, processing proceeds to step S1006. In step S1006, the Web reader accesses the hypermedia document (e.g., a homepage) specified by the URL address. In step S1007, WebFormatter instructs the Web reader to traverse the hypermedia document. Thereafter, WebFormatter selects URL address(es) from the Web and stores the addresses in container 76. Once all desired addresses have been selected and a processing function, such as print, has been activated, WebFormatter downloads data stored at the addresses in container 76 in to memory 5. WebFormatter then extracts predetermined data from the downloaded data based on the configuration information set in Optional dialog box 62, and stores the extracted data in memory 5. Thus, for example, if "Text Only" option 72 in Options Window 62 is on, only text is extracted from the downloaded data. Processing then proceeds to step S1011.

Un the other hand, if, in step S1005, a filename for an HT

ML source file is entered. WebFormatter instructs the Web reader to acce ss a first site in the file. In steps \$1008 and \$1009, the site is traversed and data is extracted and stored in the same manner as in step \$1007, described above. Then, in step \$1010, WebFormatter determines if more sites are listed in the HTML source file. If more sites are listed in the file, flow returns to step \$1008, and the next site is accessed. If no more sites are present, processing proceeds to step \$1011,

In step S1011, WebFormatter processes the extracted data in accordance with the previously set format information. For example, if Columns field 48 is set to multiple, the extracted data will be format ted into a document having multiple columns. The above processing is in itiated by activating one of Print icon 96, Edit icon 97 or Save icon 99, and is similar to the processing described above in the first embodiment, e.g., flattening the document and formatting the document based on the furmatting information. Accordingly, a detailed description thereof is omitted for the sake of brevity.

Once the documents whose URLs are stored in the container have been downloaded, formalled according to the preset formats and configurations, and converted into RTP file(s) in step S1011, in step S1012, the RTP file(s) are output. Alternatively, the RTP files(s) can be edited or saved, depending upon which icon on the graphical user interface has been activated.

The invention has been described with respect to particula r illustrative embodiments. It is to be understood that the invention is not limited to the above described embodiments and modifications there to, and that various changes and modifications may be made by those of ordinary skill in the art without departing from the spirit and scope of the appended claims.

APPENDIX 1

(47)

SAMPLE USER PROFILE

The User Profile is implemented in windows ini file format.

[Defaults]

Count-4

Title=My Daily Paper

[1]

Heading-News In Brief

Site=1

Section=Front Page

MaxLevels=5

Maxpages=10

MaxKBytes=2000

Date=today

Print=level 0

Template-1

[2]

Heading=Sports In Brief

Site=2

Section=Sports

Max Levels=0

MaxPages=10

MaxKbytes=200

KeywordFilter="Football" AND "49ers"

Date=today

Print=level 0

Template-1

[3]

Heading=Money Natters

Site-1

(48)

Section=Business

MaxLevels=1

MaxPages-100

MaxKBytcs=20000

KeywordFilter="Computer" OR "hardware" OR "Software"

Date=today

Print=all

Template=2

[4]

Heading=Sri Lanka

Site-3

Section=HotNews

MaxLevels=1

MaxPages-100

MaxKBytes=20000

Date=today

Print=leaves

Template=2

### SAMPLE SITE PROFILES

#Legend:

#%W-day of the week

#Ks section part of URL

[Defaults]

Count=3

[1]

Title=San Jose Mercury News

Username-mwickram

Password=cannon

StartData=StartHeadlines

(49)

EndData=EndHeadlines

Home Page=http://www.sjmercury.com/

SectionURL=http://www.sjmercury.com/%S.htm

SectionCount=9

Section 1-Front Page

Section 2=International

Section 3=National

Section 4-Local & State

Section 5=Editorials Commentary

Section 6=Business

Section 7=Sports

Section 8=Living

Section 9=Entertainment

[1. Sections]

Front Page=front

International=intl

National=natl

Local & State=loc

Editorials & Commentary=edit

Business=biz

Sports=spts

Living-liv

entertainment=ent

 $\lfloor 2 \rfloor$ 

Title=The San Francisco Chronicle

Home Page=http://www.sfgate.com/chronicle/

SectionURL="http:www.sfgate.com/cig-bin/chronicle/article

list.cgi?%/S:/chronicle/today"

(50)

Section Count=5

Section 1=News

Section 2=Business

Section 3=Sports

Section 4=Editorial

Section 5-Datebook

[2. Sections]

News=News: MN

Business=Business:BU

Sports=sports:SP

Editorial=Editorial:ED

Datebook=Datebook:DD

[3]

Title=The Day News

Home page=

http://www.landa.net/lakehouse/anclWeb/dailynew/

SectionURL="http://www.lanka.net/lakehouse/anclWeb/dailyne

#### w/%W/WS, btm1"

SectionCount =12

Section 1=Business

Section 2-Editorial

Section 3=Features

Section 4=Foreign

Section 5=Letters

Section 6=InBrief

Section 7=HotNews

Section 8=Probes

Section 9=Military

Section 10=Politics

(51)

Section 11=Obituaries

Section 12=Sports

[3, Sections]

Business=business/intro

Editorial=editorial/final

Features=Teatures/intro

Foreign=foreign/intro

Letters=letters/final

InBricf=inbrief/intro

||lotNews=hotnews/intro

Probes=proves/intro

Military=military/intro

Politics=politics/intro

Obituaries=obiturai/intro

Sports=sports/intro

APPENDIX 2

SYNTAX FOR RETRIBVAL, EXTRACTION AND PRINTING CRITERIA

Maximum levels to search: MaxLevels=<4>

-1: to retrieve all levels

O-n: to retrieve up to n levels

Maximum pages of the document: MaxPages=<#>

n: final document not more than n pages

Maximum size of the document: MaxKBytes=<#>

n: document size not more than n kilo bytes

Exclusion rules:

Date=today | lessthan <#>

today: retrieve only articles posted today

lessthan ;n: retrieve only articles no

more than n days old

```
<u> 整理番号=36P111J</u>
```

(52)

Retrieve=all|nosubdir|nothisdir|thissiconly

all: allow to fetch pages from other sites nosubdir: exclude URLs to subdirectories nothisdir: exclude URLs in this directory thissiteonly: fetch pages from this site only

у

Keyword search:

KeywordFilter-<keyword> (AND|OR|NOT) <keyword>:

accumulate only pages containing the combina

tion of keywords

KeywordRank-<#>;n: use fuzzy logic to rank

pages according to keyword combination in Ke

ywordFilter and keep top n ranked pages

KeywordAuthor=<author>: accumulate only

pages authored by author

ExcludeType=ads | nonEnglish

ads:exclude advertisements

nonEnglish:exclude articles that are not in

Bnglish

Flattening rules: [rint=all|leaves|level-<#>

all: include all nodes in the tree in the linear doc

ument

leaves: include all leaves in the tree in the

near document

level=<#>;n: include up to nth level of the tree in

the linear document

Formatting rules: Template-<#>

n: print according to default or user template num

ber n

# 

(53)

APPENDIX 3

DESCRIPTION OF MODULES

Appendix 3A

THE PERSONAL NEWS PROFILE BUITOR WODULE

The Profile Editor manages access to the user profiles and is represente d by CProfileMgr class. It also manages loading and saving of the profiles. The services provided by Profile Editor are:

BOOL NewProfile (CString fileName);

Creates a new profile given the

file name.

BOOL OpenProfile();

Opens the default profile.

BUUL OpenProfile(CString fileName);

Opens the named profile.

CProfileEntry\* GetFirstEntry();

Loads and returns the next prof

ile entry.

CProfileEntry\* GetNextEntry();

Loads and returns the next prof

ile entry.

BOOL WriteEntry (CProfileEntry& entry);

Saves a new entry in the profil

C.

Each profile entry contains an extraction specification and an output specification as represented by CProfileEntry class. The methods provided are:

CURL GetSiteId();

Returns the site id contained i

n the profile entry.

(54)

CBxtractionSpec GetExtractionSpec();

Returns the extraction specific ation contained in the profile entry. Extraction specification contains keywords for searching, limits for levels, pages, size in kilo bytes.

COutputSpec GetOulputSpec():

Returns the output specification number of the profile entry. Output specification contains formatting instructions and tree traversal rules.

THE Web READER MODULE

CWebPage class abstracts the interface to the Internet browser and is representative of the actual Web page. It will be responsible for fetching a Web page, extracting links or references to other URLs in the Web page, and maintaining the contents of a Web page. The methods provided are:

BOOL Load();

Fetch the Web page using the UR

L, username and password.

BUUL Parse():

- Parses the data in the Web page and creates a list of links. Also resolves the relative URLs into absolute URLs.

CURLList\* GetLinks();

Returns the list of links in th

e Neb page.

CPageData\* GetData();

Returns the actual text data co

ntained in the Web page.

void FilterContent();

Extracts title and other inform

(55)

ation according to the site data.

CString GetTitle();

Returns title and other informa

tion according to the site data.

CString GetAuthor():

Returns the author of the Web p

age.

int GetSize();

Returns the size of the data in

kilo bytes.

CNetwork class will encapsulate OLB functionality and provides communication with the Internet browser.

CString GetUsername();

- Determine the currently set use

rname.

.void SctUscrname(LPETSTR);

Set the current username in the

CNetwork object.

CString GetPassword();

Determine the currently set pas

sword.

void SetPassword(LPCTSTR);

Set the current password in the

CNetwork object.

void Close();

Disconnect any active connectio

n and reset the CNetwork object.

short Read(BSTK\*pBuffer, shortiAmount);

Read data retrieved by the Brow

(5.6)

ser.

long GetStatus();

Query the status of the current

load.

BOOL Open (LPCTSTR pURL, shortiMethod, LPCTSTR pPostData, 1 ong IPostDataSice, LPCTSTR pPostHeaders);

Initiates the retrieval of a UR

L from the network.

CString GetBrrorMessage();

Provide the caller with interna

11y generated error messages.

short GetServerStatus();

- Determine the error status reported by the server.

long GetContentType();

Return the content length (tota

1 amount of bytes) of the current load,

CString GetContentEncoding();

- Return the MIMB encoding of the current load.

CString GetExpires();

- Return when the data retrieved by this load is no longer considered valid.

CString Resolve (LPCTSTK pBase, LPCTSTR pRolative);

- Generate an absolute (fully qua

lified) URL.

BOOL IsFinished();

Determine if a load is complete

.

(57)

short BytesReady();

Inform the caller of the number

of bytes prepared to be read.

THE SITE DRIVER MODULE

The Site Driver will provide the site information to the Web Reader. The Site Driver is functionally similar to the Profile Editor and is represented by CSiteDriver class. Services provided are:

BOOL NewProfile (CString fileName);

Creates a new profile given the

file name.

BOOL OpenProfile();

Opens the default profile.

BOOL OPenProfile(CString fileName);

- Opens the named profile.

CSiteProfile\* GetFirstSite();

- Loads and returns the first sit

e entry.

CSiteProfile\* GetNextSite();

Loads and returns the next site

entry.

BOOL WriteEntry (CSiteProfile& entry);

Saves a new entry in the profil

C.

int NumberOfSites();

- Returns the number of sites specified in the profile.

An entry in the site profile will contain information about the base URL of the site, title of the news source, information about how to access the site, and various other information such as section data etc. and wi

(58)

11 he represented by CSitcEntry class. Methods provided are:

CString GetURL();

Returns the base URL of the sit

e.

CString GetUsername();

Returns the username for the si

te.

CString GetPassword();

Returns the password for the si

te.

CString GetTitle();

Returns the password for the si

te.

CString GetTitle();

Returns the title of the news s

ource.

int SectionCount();

Returns

Appendix 3B

TREE MANAGER MODULE

Tree Manager will maintain the most central data structure in this program, which is a tree of Web page nodes and is represented by the CPageTre e. CPageTree will traverse the NWW to retrieve the necessary Wcb pages according to the extraction specification and builds the tree. The meth ods provided arc:

CPageTreeNode\* GetRoot();

Returns the root node of the tr

ee.

BOOL Build (CURL URL, CBxtractionSpec& spec);

(5.9)

Builds the tree according to th

e personal news profile extraction specification.

Each node in the page tree is represented by a CPageTreeNode. Methods provided are:

BOOL AddChild(CWebPage\* page);

Adds a child node with Web page

data

CWebPage\* GetPage();

Returns the Web page contained

in the node.

int NumberUfChildren();

Returns the number of children

belonging to the node.

BUUL IsLeaf();

Returns TRUE if a leaf node, i.

e., no children.

To traverse the Web page tree, a CTrccItcrator class is defined with different traversal methods. Methods provided are:

void Reset();

Cancels the corrent transferral

, and initializes state data,

CPage TreeNode\* GetNextNode();

- Returns the next node in the tr

CPage TreeNode\* GetNextSibling();

- Returns the next node in the tr ee in a breadth first search.

CPage TreeNode\* GetNextLeaf();

Returns the next loaf in the tr

(60)

ee in a depth first search.

THE FORMATTER MODULE

Input to this module will be the Web page tree created by the Tree Manager and the output specification contained in the user profile. Pormatter will traverse the tree according to the rules specified in the output specification and the final document will be formatted using the formatting instructions in the output specification and the formatting contained in the Web pages such as headings, paragraphs and lists etc.

The output document will be in Rich Text Format (RTF) and will be access ible by many applications. RTF is a advanced formatting language for text, providing document, section and paragraph formatting, style sheets, headers and footers, and with support for Uniconde. Image formats supported are UIB, DDB, WMF, OS/2 metafiles. There is no support for Web images which are of the CIP format. A third party library will need to be purchased in order to do the conversion of the GIF to DIB format or one can be developed in-house.

The prototype creates a HTML file as the output.

The formatter is represented by the CFormatter class. The methods provided are:

BOOL OpenHTMLPile (CString fileName);

Opens the named HTML file for o

void CloseHTMLFile();

utput.

- Closes and saves the HTML file.
BOOL PrintHTML(CPageTree& root, COutputSpec& format);

- Given the root and the output s pecification, traverses the tree and prints the contents in the Web page s in HTML format.

BUUL UpenRTFFilc(CString fileName);

(6.1)

Opens the named RTF file for ou

tput.

void CloseRTFFile();

- Closes and saves the RTF file.
BOOL PrintRTF(CPageTree& root, COutputSpec& format);

- Given the root and the output s pecification, traverses the tree and prints the contents in the Web page s in RTF format.

BODL Print (CPageTree& root, COutputSpec& format);

- Given the root and the output specification a t, traverses the tree and prints the contents in the Web pages to the de fault printer.

#### 4. BRIEF DESCRIPTION OF THE DRAWINGS

Figure 1 is a perspective view showing the outward appearance of the personal news retrieval system according to the invention.

Figure 2 is a block diagram of the personal news retrieval system shown in Figure 1.

Figure 3. comprised of Figures 3A, 3B, 3C and 3D, shows re presentational diagrams illustrating an example of the transformation of information from the Web (Figure 3A) to an extracted data tree (Figure 3B), then to a flattened document (Figure 3C), and finally to a formatted document (Figure 3D) according to the invention.

Figure 4 is a representational block diagram of the manner by which a personal-news-profile for retrieving news articles via the W eb is created or edited according to the invention.

Figure 5, comprised of Figures 5A and 5B, shows flow diagrams describing how a personal-news-profile is created or edited.

Figure 6 is a representational block diagram of the manner by which news articles are retrieved from the Web and formatted with re

(62)

ference to a personal-new-profile according to the invention.

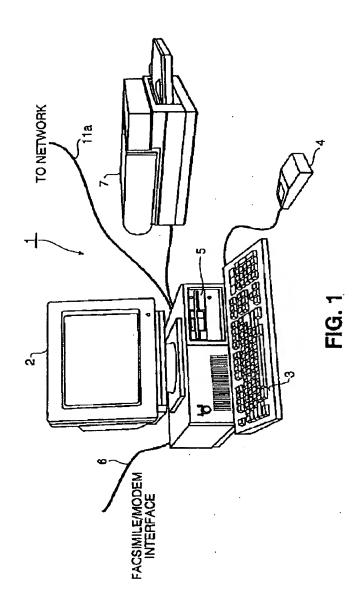
Figure 7 is a flow diagram describing how news articles ar e retrieved from the Meb with reference to a personal-news-profile.

Figure 8 is a flow diagram showing how retrieved news articles are formatted with reference to a personal news profile and sent to a print device interface.

Figures 9A to 9E depict a graphical user interface used wi th the second embodiment of the present invention.

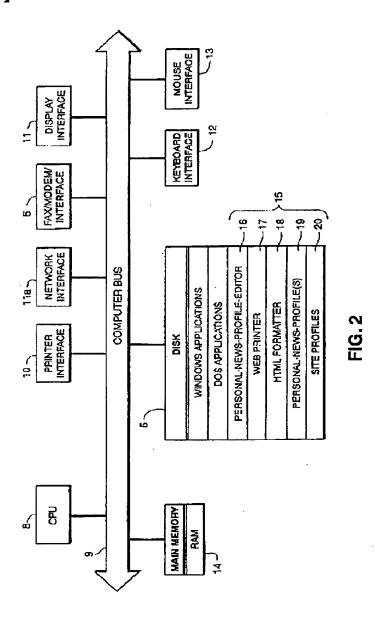
Figure 10 is a flow diagram describing the operation of the second embodiment of the invention.

[図1]



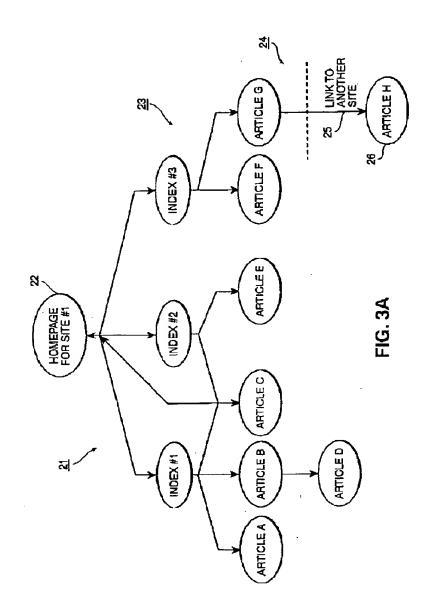
[図2]

(2)



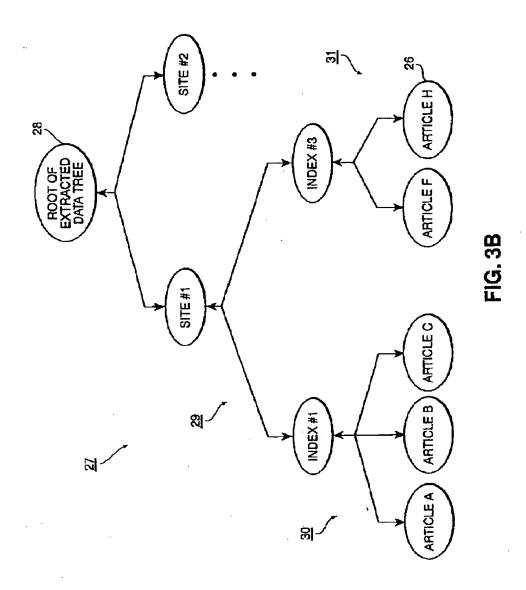
(3)

[図3A]



(4)

【図3B】



(5)

FIG. 3C

【図3C】

84/

		1														
MY PAPER	SITE #1 NAME	INDEX#1	ARTICLE A TITLE	ARTICLE A TEXT	ARTICLE B TITLE	ARTICLE B TEXT	ARTICLE C TITLE	ARTICLE C TEXT	INDEX #3	ARTICLE F TITLE	ARTICLE F TEXT	ARTICLE H TITLE	ARTICLE H.TEXT	SITE #2 NAME	• • •	

【図3D】

MY PAPER

From the <SITE #1 NAME>:

<ARTICLE A TITLE>

(영)

This is the text from article A. This is the text from article A. This is the text from article A. This is the text from

article A. This is the text from article A. This is the text from article A. This is the text from article A. This is the

**«ARTICLE H TITLE»** 

This is the text from article H. This is the text from article article H. This is the text from article H. This is the text H. This is the text from article H. This is the text from from article H.

From the <SITE #2 NAME>:

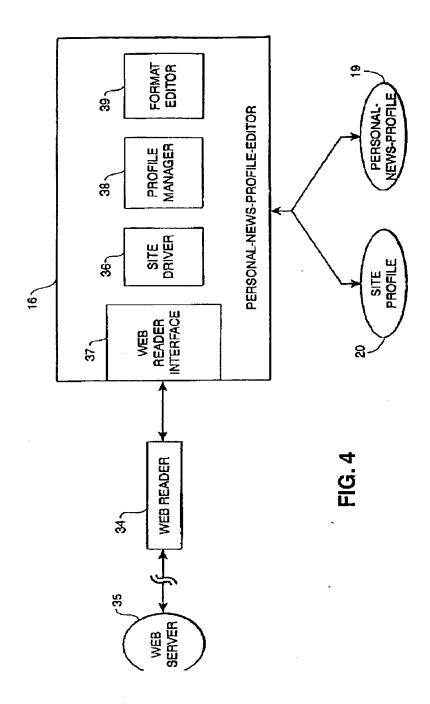
-ARTICLE X TITLE>

This is the text from article X. This is the text from article X. This is the text from article X. This is the text from

FIG. 3D

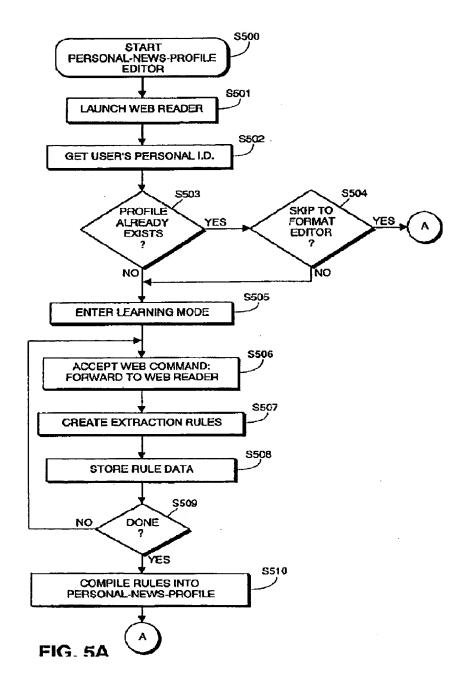
(6)

[図4]



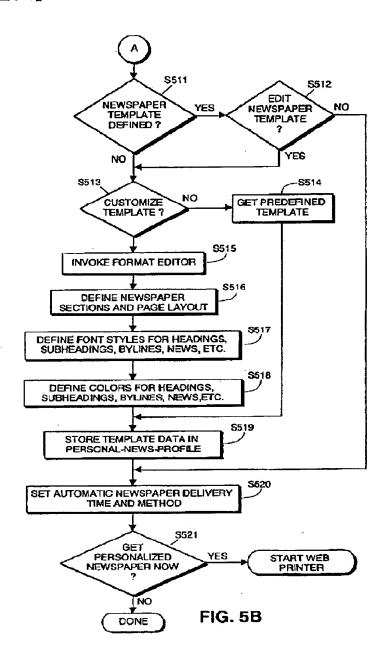
(7)

## 【図5A】



(8)

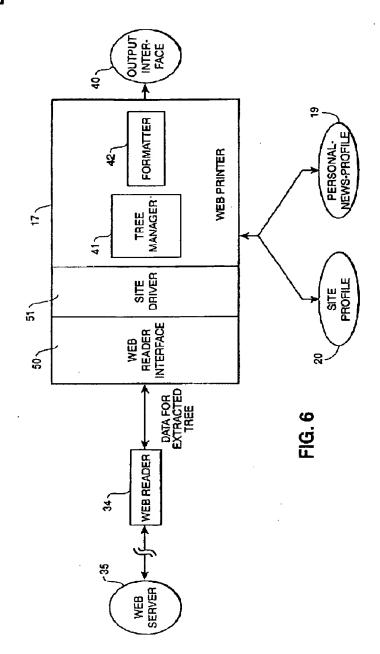
【図5B】



# 整理番号=3<u>6P111</u>J

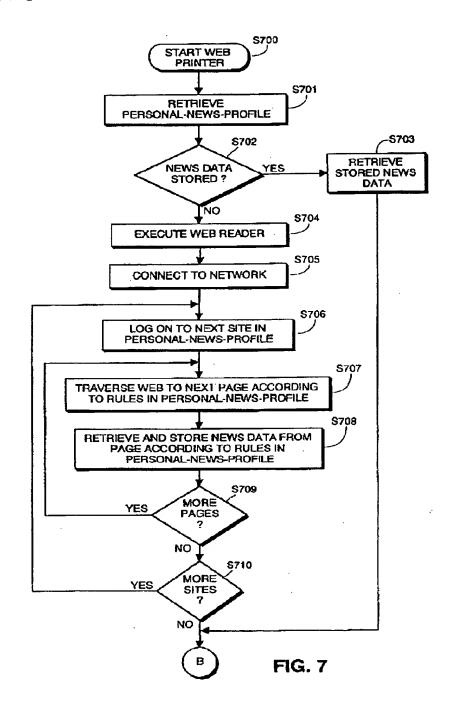
(9)

【図6】



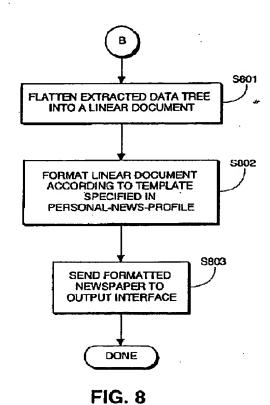
(10)

【図7】



(11)

【図8】



(12)

# 【図9A】

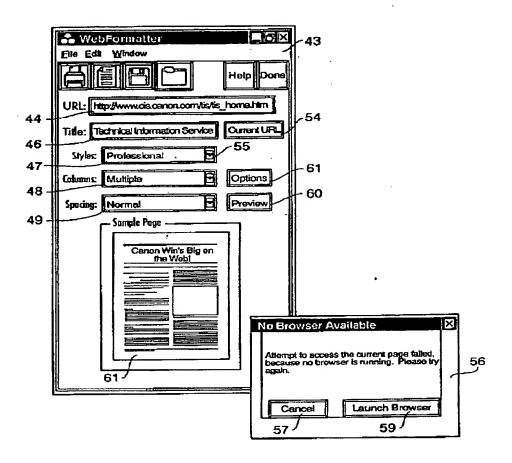
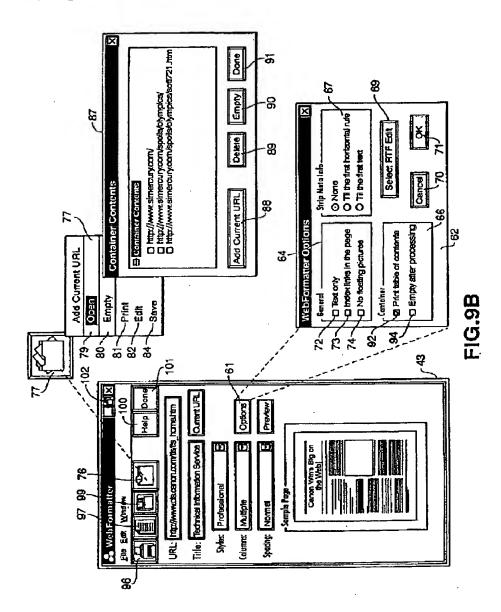


FIG.9A

(13)

[図9B]



(14)

【図9C】

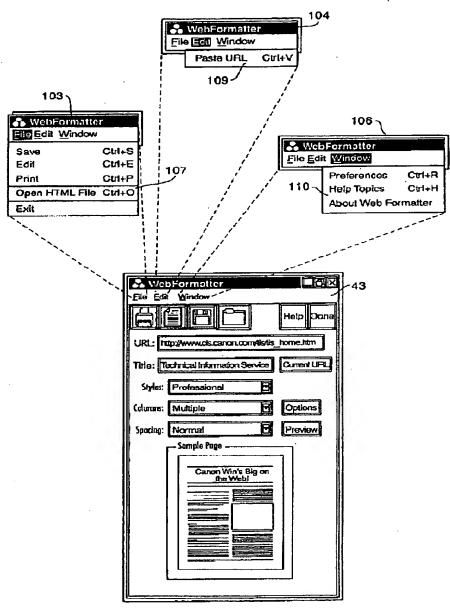


FIG.9C

(15)

## 【図9D】

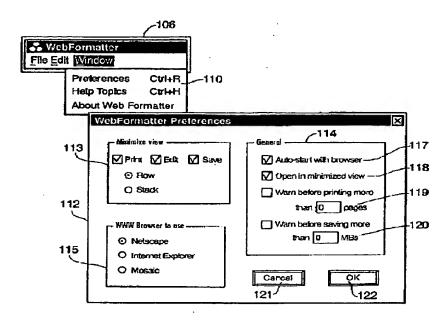
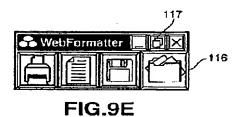


FIG.9D

[図9E]



【図10】

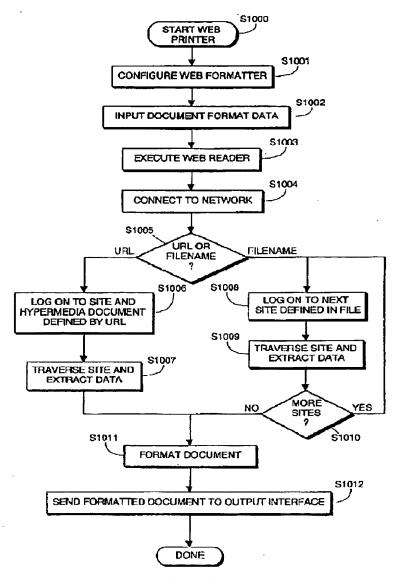


FIG. 10

### 1 ABSTRACT

A World Wide Web site data retrieval system includes an in put device for inputting data and commands to access the World Wide Web. and a memory for storing a Web site data retrieval driver which include s a Web reader, stored Web site address information, stored Web site com mands, and stored format information. The memory also stores process st eps to connect to a Web site and to issue commands within the connected Web site, and a connection to the World Wide Web. The system includes a processor for launching the Web site data retrieval driver in response to a command to access the World Wide Web. The Web site retrieval drive r, upon being launched, (1) launches the Web reader to connect to the Wo rld Wide Web via the connection, (2) retrieves the Web site address info rmation and Web site commands, (3) instructs the Web reader to access th e Web site based on the Web site address information and Web site comman ds, (4) downloads Web site data from the Web site based on the Web site commands, (5) stores the Web site data in a linear document, (6) repeats steps 1 through 5 until all addresses in the stored Web site address in formation have been accessed, and (7) formats the linear document into a personalized document based on the format information.

#### 2 REPRESENTATIVE DRAWING

Fig. 3A